

TECHNICKÁ UNIVERZITA V LIBERCI
FAKULTA TEXTILNÍ

DIPLOMOVÁ PRÁCE

LIBEREC 2010

Bc. Michaela ROĐOMOVÁ

TECHNICKÁ UNIVERZITA V LIBERCI

Fakulta textilní

Katedra hodnocení textilií

Studijní program: N3108 Průmyslový management

Studijní obor: Management jakosti

Zaměření: Management jakosti

**MÍRY PODOBNOSTI A JEJICH VYUŽITÍ PRO
VYHLEDÁVÁNÍ V DATABÁZÍCH TEXTUR
TEXTILIÍ A TEXTILNÍCH VZORŮ**

**SIMILARITY MEASURES AND THEIR USAGE FOR
RETRIEVAL IN TEXTILE TEXTURE AND TEXTILE
DESIGN DATABASES**

Michaela Rođomová

KHT – 031

Vedoucí diplomové práce: prof. RNDr. Aleš Linka, CSc.

Rozsah práce

Počet stran textu: 87

Počet obrázků: 53

Počet tabulek: 2

Počet příloh: 5

Zadání diplomové práce

(vložit originál)

Prohlášení

Byla jsem seznámena s tím, že na mou diplomovou práci se plně vztahuje zákon č. 121/2000 Sb., o právu autorském, zejména § 60 – školní dílo.

Beru na vědomí, že Technická univerzita v Liberci (TUL) nezasahuje do mých autorských práv užitím mé diplomové práce pro vnitřní potřebu TUL.

Užiji-li diplomovou práci nebo poskytnu-li licenci k jejímu využití, jsem si vědoma povinnosti informovat o této skutečnosti TUL; v tomto případě má TUL právo ode mne požadovat úhradu nákladů, které vynaložila na vytvoření díla, až do jejich skutečné výše.

Diplomovou práci jsem vypracovala samostatně s použitím uvedené literatury a na základě konzultací s vedoucím diplomové práce a konzultantem.

V Liberci dne 30. června 2010

.....
Podpis

Pod'akovanie

Rada by som touto cestou pod'akovala všetkým, ktorí sa zaslúžili o vznik mojej diplomovej práce a predali mi svoje bohaté znalosti a skúsenosti.

Predovšetkým by som rada pod'akovala vedúcemu diplomovej práce prof. RNDr. Alešovi Linkovi, CSc. za metodické a odborné vedenie a v neposlednom rade za ústretový prístup pri zostavovaní diplomovej práce.

Moje pod'akovanie patrí tiež Ing. Marošovi Tunákovi PhD. a Ing. Jirkovi Kulovi pri realizácii tejto práce.

Moje osobité pod'akovanie patrí rodičom, ktorí mi umožnili študovať a po celú dobu štúdia ma podporovali.

V neposlednom rade ďakujem môjmu priateľovi, ktorý ma po túto dobu podporoval.

Anotace

Tato diplomová práce se zabývá mírami podobnosti a jejich použitím pro vyhledávání v databázi textur textilií a textilních vzorů. V práci je vyhledávání obrazu textilie realizované pomocí metody normalizované vzájemné korelace (*NCC*), s použitím metody latentního sémantického indexování (*LSI*) a pomocí metody invariantních momentů. Principem metody latentního sémantického indexování je redukce dimensionalita a výpočet kosinové míry jako míry podobnosti mezi obrazem dotazované tkaniny a obrazy textilií v databázi textur. Metoda *LSI* je citlivá na rotaci obrazu nebo vzoru v obraze. V tomto případě je lepší metodu *LSI* aplikovat nikoli na obraz tkaniny, ale na jeho výkonové spektrum získané z *2D* Fourierovy transformace obrazu. Dochází k porovnání obrazu výkonového spektra hledané tkaniny s obrazy výkonových spekter textilií z databáze. Další použitá metoda byla metoda založená na invariantních momentech, jako míra podobnosti zde byla použita Euklidova vzdálenost. Uvedené metody byly testovány na obrazech naskenovaných tkanin a na obrazech plošných textilií z databáze textur. V závěru práce je porovnána efektivita jednotlivých metod.

Klíčová slova

míra podobnosti; vlastní čísla; latentní sémantické indexování; Fourierova transformace; invariantní momenty; korelace; databáze textur;

Annotation

The thesis deals with the similarity measures and their usage for the data retrieval from textile textures database. Textile image retrieval is realized using the normalized cross correlation method (*NCC*), latent semantic indexing method (*LSI*) and the method of invariant moments. The principle of latent semantic indexing method is reduction of dimensionality and the calculation of cosine measure as a similarity measure between queried textile image and the textile images in the database. *LSI* method is sensitive to the rotation of an image or pattern in an image. In this case it is better alternative to apply the *LSI* method not to an image but to image of its power spectrum which is obtained from *2D* Fourier transform of the images. Then the spectra of the queried and the database images are compared. Another described method is based on the invariant moments. Euclidean distance is used as a similarity measure. These methods were tested on images of scanned textiles and images obtained from textile textures database. The final part compares the efficiency of the described methods.

Key words

Similarity Measure; Eigenvalues; Latent Semantic Indexing; Fourier Transform; Moment Invariants; Correlation; Texture Database;

Obsah

Zoznam symbolov a skratiek	8
Úvod	10
1 Zhrenutie súčasného stavu	11
2 Digitálny obraz	13
2.1 Delenie obrazu	13
2.1.1 Binárny obraz	14
2.1.2 Intenzitný obraz	14
2.1.3 Farebný obraz – <i>RGB</i>	14
2.1.4 Indexovaný obraz	14
2.2 Textúra	15
3 Miery podobnosti	15
3.1 Normalizovaná vzájomná korelácia	15
3.2 Miera podobnosti pomocou vlastných čísiel	21
3.2.1 Korešpondenčná mapa	21
3.2.2 Metóda porovnania pomocou vlastných čísiel	24
3.3 Latentné sémantické indexovanie	27
3.3.1 Extrakcia vlastností pomocou metódy <i>LSI</i>	27
3.3.2 Klasická metóda <i>LSI</i> ako rozšírenie vektorového modelu	28
3.3.3 <i>LSI</i> pre kolekciu obrázkov	31
3.3.3.1 Rekonštrukcia obrázka	31
3.3.4 Miera podobnosti pre porovnávanie obrázkov	31
4 Testovacia obrazová sada	33
4.1 Naskenované tkaniny	33
4.2 Naskenované tkaniny v 4 rôznych smeroch	33
4.3 Databáza textúr textílií a textilných vzorov	33
4.4 Testovacia sada 1	35
4.5 Testovacia sada 2	41
4.6 Testovacia sada 3	45

5	Dvojrozmerná diskretná Fourierová transformácia	51
5.1	Testovacia sada 4 - vyhodnotenie metódy <i>LSI</i> pomocou <i>2D DFT</i>	52
5.1.1	Naskenované tkaniny v rôznych smeroch	53
5.1.2	Náhodne vybrané tkaniny z kolekcie naskenovaných tkanín	57
5.1.3	Vyhľadávanie v databáze textúr textílií a textilných vzorov	60
6	Invariantné (<i>nemenné</i>) momenty	65
6.1	Testovacia sada 5	68
7	Porovnávanie koreláciou	74
7.1	Testovacia sada 6	76
	Záver	83
	Literatúra	85
	Prílohy	87

Zoznam symbolov a skratiek

$2D$	dvojrozmerný
$3D$	trojrozmerný
PCB	(<i>Printed Circuit Boards</i>) plošné tlačené spoje
(x,y)	súradnice obrazového bodu
$f(x,y)$	obrazová funkcia
m	počet riadkov okna
n	počet stĺpcov okna
RGB	(<i>R – Red, G – Green, B – Blue</i>) farebný obraz
NCC	(<i>Normalized Cross-Correlation</i>) normalizovaná vzájomná korelácia
f	obrázok (kontrolovaný/ porovnávaný obrázok)
w	referenčná šablóna (vzorový obrázok)
γ	normalizovaná vzájomná korelácia
\bar{f}	stredná hodnota úrovne šedi podobrázku v f
\bar{w}	stredná hodnota úrovne šedi podobrázku v w
L	celkový počet úrovní šedi
C	suma pixelov
i	úroveň šedi v referenčnej šablóne
j	úroveň šedi v kontrolovanom obrázku
M	kovariančná matica
λ_S, λ_L	vlastné čísla
SVD	(<i>Singular Value Decomposition</i>) singulárne číslo rozkladu
LSI	(<i>Latent Semantic Indexing</i>) latentné sémantické indexovanie
A	matrica dokumentu
U	matrica vektorov
Σ	matrica
$\cos\theta$	kosínová miera
q	dotazovací vektor
φ	uhol
bmp, jpg	obrazové formáty

k	prvých k najdôležitejších konceptov (vysoké singulárne číslo)
$2D\ DFT$	(<i>2 Dimensional Discrete Fourier Transforms</i>) dvojrozmerná diskretná Fourierová transformácia
$F(u,v)$	koeficient diskretnej Fourierovej transformácie
$2D\ DIFT$	(<i>2 Dimensional Discrete Inverse Fourier Transforms</i>) dvojrozmerná diskretná inverzná Fourierová transformácia
$R(u,v)$	reálna časť $F(u,v)$
$I(u,v)$	imaginárna časť $F(u,v)$
$P(u,v)$	výkonové spektrum
sim	miera podobnosti
atď.	a tak ďalej
t.j.	to je
DIS	dokumentografické informačné systémy
m_{pq}	$2D$ moment rádu $(p+q)$
u_{pq}	centrálny moment rádu $(p+q)$
η_{pq}	normalizovaný centrálny moment rádu $(p+q)$
ϕ	invariantný moment

Úvod

V súčasnej dobe, s nárastom informačných technológií, vzniká obrovské množstvo multimediálnych dát. Medzi tieto dáta sa zaraďujú textové, obrazové a zvukové dokumenty. Pri práci s týmito dokumentmi sa často rieši otázka ako v nich rýchlo a efektívne vyhľadávať. Systémy pre údržbu a vyhľadávanie dokumentov sa nazývajú Dokumentografické informačné systémy (*DIS*). Ukladanie a vyhľadávanie informácií je oblasť, ktorá bola po stáročia doménou knihovníctva. Vzhľadom k tomu, že spracovávané dokumenty môžu mať rôznu štruktúru, je nutné hľadať vhodné metódy pre ukladanie a vyhľadávanie takýchto dokumentov. Rozmanité metódy a modely vyvinuté v oblasti počítačových vied pri vyhľadávaní informácií (*Information Retrieval, IR*) našli široké uplatnenie v rôznych oblastiach súčasného života.

Mocným nástrojom pre meranie podobnosti v počítačovom videní je normalizovaná vzájomná korelácia (*Normalized Cross-Correlation, NCC*). Používa sa pri aplikáciách rozpoznania objektov a pri detekcii chýb v obrazoch. Úspešnosť tejto metódy je však nízka pre obrázky s malými rozdielmi. Metóda latentného sémantického indexovania (*Latent Semantic Indexing, LSI*) je vhodná pri vyhľadávaní informácií a slúži na odstránenie prebytočných informácií a šumu vo vstupných údajoch. Jedná sa o vektorový model, kde je databáza chápaná ako matica a dotaz užívateľa predstavuje vektor. Medzi dotazom užívateľa a dokumentmi v databáze sa vypočíta vhodná miera podobnosti. Metóda využíva singulárny rozklad (*Singular Value Decomposition, SVD*) a uplatňuje sa pri rozpoznávaní a rekonštrukcii tváre, vyhľadávaní informácií v obrázkoch, identifikácii ľudí pomocou fotografií očných dúhoviek a podobne. Ďalšou použiteľnou metódou vyhľadávania podobných obrazov a vyhľadávania v databázach je metóda založená na invariantných momentoch, ako miera podobnosti môže byť použitá Euklidova vzdialenosť.

Cieľom tejto práce je zisťovanie a overenie možnosti vyhľadávania podobných obrazov plošných textílií pomocou miery podobnosti v databáze textúr textílií a textilných vzorov. Navrhnuté metódy budú testované na sade naskenovaných obrazov tkanín a na sade obrazov plošných textílií z existujúcej databázy textúr textílií a textilných vzorov. Algoritmy pre jednotlivé metódy a postupy budú zostavené vo forme m-súborov v programovom prostredí MATLAB. V závere práce sú zhodnotené jednotlivé metódy a zároveň porovnaná ich efektivita.

1 Zhrnutie súčasného stavu

V nasledujúcom texte je uvedený stručný prehľad zisťovania a porovnávania miery podobnosti obrazových údajov založený na normalizovanej vzájomnej korelácii, pomocou latentného sémantického indexovania a pomocou Fourierovej transformácie.

V práci [1] je prezentovaná normalizovaná vzájomná korelácia. Táto základná metóda je dobrým nástrojom pre rozpoznanie veľkých rozdielov medzi porovnávanými obrázkami. Hlavnou úlohou tejto metódy je meranie podobnosti na základe vlastných čísiel medzi dvoma šedotónovými obrázkami, za účelom odhalenia chýb. Metóda spočíva v prevode porovnávaných šedoúrovňových obrázkov na dvojice hodnôt úrovne šedi na danej pozícii pixelov v obrázku. Výsledkom sú dvojice šedých hodnôt pre každý pixel, ktoré predstavujú mapu korešpondencie. Ak sú oba obrázky zhodné, výsledkom porovnania je diagonálne priama čiara. V opačnom prípade to vedie k nelineárnemu tvaru v mape korešpondencie. Z tejto mapy sa zostavuje kovariančná matica a na jej základe sa vypočítajú vlastné čísla. Menšie vlastné číslo kovariačnej matice šedých úrovní je použité ako miera podobnosti, ktorá je pre dva identické obrázky približne nulová a pre rozdielne obrázky značne veľká. Experimentálne výsledky ukazujú, že daná metóda má výborné výsledky rozpoznávania voči normalizovanej vzájomnej korelácii. Na rozdiel od metódy odpočítania obrázkov je vysoko citlivá na drobné odchýlky a veľmi tolerantná voči rôznym stupňom jasu. Metóda je veľmi vhodná na odhalenie chýb. Meranie na plošných tlačených spojoch *PCB (Printed Circuit Boards)* ukázalo efektivitu merania podobnosti pre detekciu chýb v zložitých obrázkoch.

Pri vyhľadávaní informácii v moderných technológiách veľkú rolu hrajú výpočty vlastných čísiel a vlastných vektorov. Pokusy, ktoré ukazujú súvislosť medzi smerodajnou odchýlkou a singulárnymi číslami rozkladu *SVD (Singular Value Decomposition)* popisuje autor v práci [2]. Vyhľadávanie v kolekcii webových obrázkov sa prevádza pomocou metódy latentného sémantického indexovania *LSI (Latent Semantic Indexing)*. Táto metóda je vhodná pri vyhľadávaní informácií. Bolo vybraných 15 najpodobnejších obrázkov, ktoré sa roztriedili podľa koeficientu podobnosti. Podobné obrázky sa automaticky zhluovali do skupín. Metódu *SVD* možno úspešne použiť pri rozpoznávaní a rekonštrukcii tváre, vyhľadávaní informácií v obrázkoch, identifikácii ľudí pomocou fotografií očných

dúhoviek, pre extrakciu informácií z internetových katalógov. Matematické výpočty boli prevádzané pomocou MATLABu.

V práci [3] autori prezentujú vytváranie vektorov obrázkov (extrakciu vlastností z obrázku) v modeli *LSI* (pomocou singulárneho rozkladu). Autori popisujú špecifické použitie modelu *LSI* pre reprezentáciu obrázkov spolu s využitím *M*-stromu ako indexovacej štruktúry pre efektívne vyhľadávanie. Pomocou aplikácie *LSI* na obrázky sa vizualizovali niektoré aspekty *LSI*, ktoré nie sú pri klasickom použití vo vektorovom modeli *DIS* priamo viditeľné.

Oblasť nazývaná *Information Retrieval* (vyhľadávanie informácií) sa zaoberá spracovaním veľkého množstva informácií. Rôzne metódy a modely vyhľadávania informácií našli široké uplatnenie v mnohých oblastiach súčasného života. Autor v práci [7] sa zaoberal vektorovým modelom a metódou singulárneho rozkladu (*SVD*) metódy *LSI*. Vektorový model je model, kde je dokument reprezentovaný ako vektor vo viacrozmernom vektorovom priestore. Multimediálny dokument je chápaný ako ucelený blok informácií. Metóda *SVD* je schopná zachytiť skryté väzby medzi termínmi a databázami pri redukcii vysoko-dimenzionálneho priestoru. Užívateľovi ponúka dokumenty podľa významu a nie podľa lexikálneho obsahu.

Mnohé defekty tkaniny sú veľmi malé a nerozlíšiteľné. Prístup založený na Fourierovej transformácii na odhalenie štrukturálnej chyby v tkanine je popísaný v práci [10]. Autori použili simulované modely na pochopenie vzťahu medzi štruktúrou tkaniny v priestorovej a frekvenčnej oblasti. Použili dva diagramy nazývané centrálné priestorové frekvenčné spektrá. Túto metódu autori aplikovali na tkaninách, ktoré obsahovali chyby – dvojité priadza, chýbajúca priadza, roztrhaná tkanina, zmena hustoty priadze. Vzhľadom k tomu, že 3D frekvenčné spektrum ide veľmi ťažko analyzovať bol navrhnutý prístup centrálného priestorového frekvenčného spektra pre zvýšenie účinnosti analýzy procesu. Experimenty ukázali, že získané parametre môžu byť použité ku klasifikácii chýb tkaniny.

V nasledujúcej časti práce sú konkrétnejšie popísané jednotlivé metódy merania miery podobnosti. Každá z metód bola podrobená testovaniu, pričom priebeh sa realizoval na testovacej obrazovej sade. V závere sa vyhodnotí efektivita použitých metód.

2 Digitálny obraz

Obraz je obecné akékoľvek grafické vyjadrenie. Príkladom je obraz na sietnici ľudského oka alebo obraz videný televíznou kamerou. Tieto obrazy majú plošnú povahu – dvojrozmernú ($2D$). Obrazy môžu byť aj trojrozmerné ($3D$). Rozmery sú vytvárané optickými zariadeniami ako sú kamery, zrkadlá, šošovky, ďalekohľady, mikroskopy, vodná hladina.

Spojité funkcia $f(x,y)$ dvoch argumentov, súradníc v rovine, je matematickým modelom obrazu. Táto funkcia $f(x,y)$ sa nazýva obrazová funkcia. Jas je veličina, ktorá vyjadruje vlastnosti obrazového signálu spôsobom, ktorý zodpovedá vnímaniu obrazu človekom. Intenzita je najčastejšie hodnotou obrazovej funkcie. Používaním jasu ako základnej veličiny sa dá vyhnúť popisu zložitého optického procesu vytvárania obrazu.

Obrazová funkcia sa delí na spojitú a diskretnú (digitálnu). Spojitá funkcia má definičný obor i obor hodnôt spojitý. Ku každému bodu týchto oborov sa dá nájsť ľubovoľne blízky bod. Ak množina diskretných bodov tvorí definičný obor, a ak je oborom hodnôt diskretná množina, funkcia sa nazýva diskretná (digitálna, číslicová).

Trojrozmernú povahu má prostredie, v ktorom sa pohybuje človek. Dvojrozmerná obrazová funkcia je výsledkom perspektívneho zobrazenia časti $3D$ prostredia. Tento model je verným obrazom reality a zodpovedá obrazu získanému v dierkovej komore. Pri perspektívnom zobrazení z $3D$ prostredia do $2D$ obrazovej roviny sa stratí veľa informácií.

V jednoduchšom prípade je obraz monochromatický. Je reprezentovaný jedinou obrazovou funkciou $f(x,y)$. V zložitých prípadoch sa pracuje s multispektrálnym (farebným) obrazom. Každé dvojici plošných súradníc (x,y) zodpovedá vektor hodnôt. Farba je vlastnosť objektu spojená s jej schopnosťou odrážať elektromagnetické vlnenie rôznych vlnových dĺžok [4].

2.1 Delenie obrazu

Obraz možno deliť nasledovne [4], [5]:

2.1.1 Binárny obraz

Binárny obraz je logické pole tvorené z núl a jednotiek. Jednotky predstavujú bielu farbu, ktorá naznačuje objekty. Nuly predstavujú čiernu farbu, ktorá naznačuje to ostatné – pozadie. Binárny obraz reprezentuje informáciu o obrazovom bode jedným bitom.

2.1.2 Intenzitný obraz

Intenzitný obraz je údajová matica, ktorej hodnoty boli zmenené aby reprezentovali intenzitu. Keď prvky intenzity obrazu sú z triedy *uint8* alebo *uint16*, majú celočíselné hodnoty v rozsahu $[0,255]$ a $[0,65535]$. Ak je obraz z triedy typu *double*, hodnoty sú s desatinou čiarkou. Podľa konvencie sú hodnoty intenzitného obrazu v rozsahu $[0,1]$.

2.1.3 Farebný obraz – RGB

Farebný signál sa skladá z troch samostatných zložiek *RGB* (*R* – červená, *G* – zelená, *B* – modrá). Zmiešaním zložiek vznikne farebný obraz poľa $m \times n \times 3$ farebných pixelov. Každá zložka sa digitalizuje, prenáša a prípadne spracováva počítačom samostatne.

2.1.4 Indexovaný obraz

Indexovaný obraz má dve zložky – údajovú maticu celých čísiel *X* a farebnú mapu matice. Maticová mapa je pole $m \times 3$ triedy *double* obsahujúca hodnoty s desatinnou čiarkou v rozsahu $[0,1]$. Dĺžka poľa *m* odpovedá počtu farieb, ktoré definuje. Každý riadok mapy určuje červenú, zelenú a modrú zložku jednej farby. Indexovaný obraz používa „priame mapovanie“ intenzity pixelov do hodnôt mapy farieb. Farba každého pixelu je určená použitím zodpovedajúcej hodnoty z celočíselnej matice *X* ako ukazovateľa do mapy. Ak matica *X* obsahuje hodnoty typu *double*, potom všetky jej prvky s hodnotou menšou alebo rovnou 1 ukazujú na prvý riadok mapy, ďalej prvky s hodnotou 2 na druhý riadok mapy atď. Ak matica *X* obsahuje hodnoty typu *uint8* alebo *uint16*, potom všetky prvky s hodnotou 0 ukazujú na prvý riadok v mape, prvky rovnajúce sa 1 na druhý riadok, prvky rovnajúce sa 2 na tretí riadok a podobne.

2.2 Textúra

Slovo textúra pochádza z latinského slova „*textura*“, čo znamená tkanina, látka. Obecné textúra vyjadruje vnútornú štruktúru, stavbu, usporiadanie či zloženie určitého telesa. Pod pojmom textúra [6] sa rozumie:

- Charakteristická štruktúra pretkaných a prepletených nití, prameňov, a iných elementov – hrubá textúra.
- Charakteristické štruktúry materiálu, predmetu, s ohľadom na veľkosť, tvar, usporiadanie: textúry piesočnatej pôdy.

Textúra je miera odchýlky intenzity povrchu, kvantifikujúca vlastnosti ako je hladkosť, drsnosť a pravidelnosť.

V práci sú použité farebné obrazy prevedené do šedotónového obrazu. Obrázky tkaniny možno zaradiť medzi textúrne obrazy.

3 Miery podobnosti

Miera podobnosti je hodnota, ktorá kvantitatívne charakterizuje podobnosť rôznych kvantitatívnych javov. Existujú rôzne metódy založené na miere podobnosti a v nasledujúcom texte sú vybrané metódy konkrétne popísané.


3.1 Normalizovaná vzájomná korelácia

Normalizovaná vzájomná korelácia *NCC* (*Normalized Cross-Correlation*) [1], [11] je mocným nástrojom pre meranie podobnosti v počítačovom videní, ktoré sa používa na rozpoznávanie objektov a pri detekcii chýb. Tradičná normalizovaná vzájomná korelácia medzi obrázkom f a referenčnou šablónou w je daná vzťahom

$$\gamma = \frac{\sum_{x=0}^{m-1} \sum_{y=0}^{n-1} [f(x, y) - \bar{f}] \times [w(x, y) - \bar{w}]}{\left\{ \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} [f(x, y) - \bar{f}]^2 \times \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} [w(x, y) - \bar{w}]^2 \right\}^{1/2}}, \quad (1)$$


kde $m \times n$ je veľkosť okna v pixeloch, \bar{f} a \bar{w} sú stredné hodnoty úrovni šedi podobrázkov v f a w .

Normalizovaná korelácia γ je v intervale $< -1, 1 >$. Indikuje zhodu medzi obrázkom a referenčnou šablónou. Hľadanie objektu v kontrolovanom obrázku sa prevádza pomocou posuvného okna, ktoré postupne po pixeloch porovnáva kontrolovaný obrázok obr. 1 (a) s referenčnou šablónou obr. 1 (b). Proces sa opakuje pre všetky pixely na celom obrázku. Pre každú dvojicu podobrázku je vypočítaná vzájomná korelácia. Maximálne hodnoty korelácie indikujú nájdenie vzoru v kontrolovanom obrázku. Malá miera podobnosti (pod stanovenou prahovou hodnotou) signalizuje prítomnosť chyby. Použitie normalizovanej vzájomnej korelácie pre určenie podobnosti pri detekcii chýb vedie k tomu, že táto metóda nemusí byť dostatočne citlivá na zistenie drobných anomálií a môže viesť k nesprávnym výsledkom.



Obr. 1 Porovnávanie pomocou posuvného okna (a) kontrolovaný obrázok a (b) referenčná šablóna.

Na obr. 2 je príklad tkaniny v šedoúrovňovom obraze s bodkovaným štvorcom o veľkosti $m \times n$. Ružový štvorec (ďalej len podobrázok) predstavuje výrez, ktorý slúži k porovnaniu jednotlivých obrázkov. Obr. 2 (a) ukazuje referenčnú šablónu časti tkaniny, obr. 2 (b) bezchybný obrázok a na obr. 2 (c) je znázornený obrázok, ktorý obsahuje chybu.




Obr. 2 Obrázky tkaniny s bodkovým štvorcom: (a) referenčná šablóna, (b) bezchybný obrázok, (c) chybný obrázok.


Výsledná hodnota korelácie γ (pre celý obrázok) medzi referenčnou šablónou obr. 3 (a1) a bezchybným obrázkom obr. 3 (b1) je 0,99 z čoho vyplýva, že oba porovnávané obrázky sú zhodné. Bola použitá rôzna kvalita obrázkov. Ak by sa porovnávali obrázky rovnakej kvality výsledná hodnota korelácie medzi referenčnou šablónou a bezchybným obrázkom by bola rovná 1. Pri porovnávaní referenčnej šablóny obr. 4 (a1) a chybného obrázku 4 (b1) hodnota korelácie γ dosahuje až 0,81 čo značí, že porovnávaný obrázok môže byť nesprávne označený za bezchybný.

Pre lepšie zistenie chyby je vhodná výsledná korelácia γ jednotlivých podobrázkov, pretože presnejšie odhalí chyby. Veľkosť podobrázku bola stanovená na 20×20 pixelov s prahom 0,8. Pre vizuálnu predstavu na obr. 3 (c) a 4 (c) je zobrazená matica korelačných koeficientov obrázku v binárnom obraze (bol použitý prah 0,8). Pri porovnávaní sa použili obrázky s počtom úrovní šedi 256 a veľkosti 200×156 pixelov. Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom `ncc.m`.

Celková korelácia γ obrázku je citlivá na odhalenie drobnej chyby. Vyhodnocuje ich za správne. Preto normalizovaná vzájomná korelácia nie je vhodná na odhalenie drobných chýb.




Obr. 3 Porovnanie obrázkov pomocou *NCC*: (a) referenčná šablóna a (a1) referenčná šablóna v šedoúrovňovom obraze, (b) bezchybný obrázok a (b1) bezchybný obrázok v šedo úrovňovom obraze, (c) výsledok zobrazenia.




Obr. 4 Porovnanie obrázkov pomocou *NCC*: (a) referenčná šablóna a (a1) referenčná šablóna v šedoúrovňovom obraze, (b) chybný obrázok a (b1) chybný obrázok v šedo úrovňovom obraze, (c) výsledok zobrazenia.

Na obr. 5 je príklad porovnania obrázkov pri rôznych veľkostiach podobrázkov 5×5 , 20×20 a 35×35 pixelov s prahom 0,8. Obr. 5 (a) znázorňuje referenčnú šablónu, ktorá sa porovnáva s bezchybným obrázkom obr. 5 (b) a s obrázkom, ktorý obsahuje defekt zobrazený na obr. 5(c). Z výsledkov vyplýva, že malé okienko (5×5 pixelov) pokryje len malú plochu obrázku a preto generuje viac šumu na výslednom obrázku ako je vidieť na obr. 5 (d1). Chyba, v kontrolovanom obrázku, je pri použití malého okienka (5×5 pixelov) zle viditeľná obr. 5 (e1) a môže dôjsť k nepresnostiam pri vyhodnotení. Naopak veľké okienko (35×35 pixelov) nemusí vykonať lepšiu detekciu ako je vidieť na obr. 5 (e3). Miesto znázornenia chyby je väčšie ako je na obr. 5 (c). Vzhľadom k efektívnosti a náročnosti detekcie je doporučená veľkosť podobrázka medzi 20×20 až 30×30 pixelov.



Obr. 5 Vplyv zmeny veľkosti podobrázkov: (a) referenčná šablóna, (b) bezchybný obrázok, (c) chybný obrázok, (d1-d3) výsledky porovnania (a) oproti (b) pri veľkosti podobrázkov 5×5 , 20×20 , 35×35 , (e1-e3) výsledky porovnania (a) oproti (c) pri veľkosti podobrázkov 5×5 , 20×20 , 35×35 .

Použitie metódy *NCC* nie je vhodné pre obrázky, ktoré majú jednoliatu plochu. V rovnici (1) dochádza k deleniu nulou a tým vychádzajú neúplné výsledky, ako je možné vidieť na obr. 6.



Obr. 6 Porovnanie obrázkov pomocou *NCC*: (a) referenčná šablóna a (a1) referenčná šablóna v šedo úrovňovom obraze, (b) bezchybný obrázok a (b1) bezchybný obrázok v šedo úrovňovom obraze, (c) chybný obrázok a (c1) chybný obrázok v šedo úrovňovom obraze, (d) výsledok zobrazenia obr. (a1) a obr. (b1), (e) výsledok zobrazenia obr. (a1) a obr. (c1).

Pri porovnávaní jednotlivých obrázkov záleží hlavne na stanovení veľkosti podobrázku a veľkosti prahu. Vysoký prah je dobrý pri dvoch identických obrázkoch. Záleží i na kompresii, kvalite obrázku a v akom obrazovom formáte je uložený. Lepšie je pracovať s bitmapovými obrázkami *JPEG*, viac sa podobajú realite.

3.2 Miera podobnosti pomocou vlastných čísiel

3.2.1 Korešpondenčná mapa

Metóda rozpoznávania podobnosti pri detekcii chýb je založená na vlastných hodnotách merania medzi dvoma šedoúrovňovými obrázkami. Pomocou obrázku $f(x,y)$ a referenčnej šablóny $w(x,y)$ sa zostrojí 2D mapa, so súradnicami $[w(x,y), f(x,y)]$ pre každý pixel obrázku (x,y) , ukazujúca rozloženie šedých úrovní pre oba obrázky. Výsledok rozloženia dvojíc šedých úrovní sa nazýva šedoúrovňová mapa podobnosti [1].

Dvojice šedoúrovňových hodnôt porovnávaných obrázkov (na rovnakých x, y súradniciach) sú použité ako súradnice grafu mapy podobnosti, kde os x predstavuje šedé úrovne referenčnej šablóny w a os y šedé úrovne kontrolovaného obrázku f . Rozpätie každej osi v mape je $0, 1, 2, \dots, L$, kde L predstavuje celkový počet úrovní šedi. Každý pixel v obrázku a v šablóne na súradniciach (x,y) generuje bod korešpondencie so súradnicami $[w(x,y), f(x,y)]$ v mape podobnosti. Pretože rôzne pixely v obrázku a šablóne môžu generovať rovnaký bod v mape podobnosti, ide o transformáciu $N:1$ (nie o prosté zobrazenie). N predstavuje viac pixelov rovnakej farby v obrázku. Veľkosť okna je $m \times n$ a $C[i,j]$ je suma pixelov, ktoré majú šedú hodnotu i v referenčnej šablóne w a šedú hodnotu j v obrázku f .

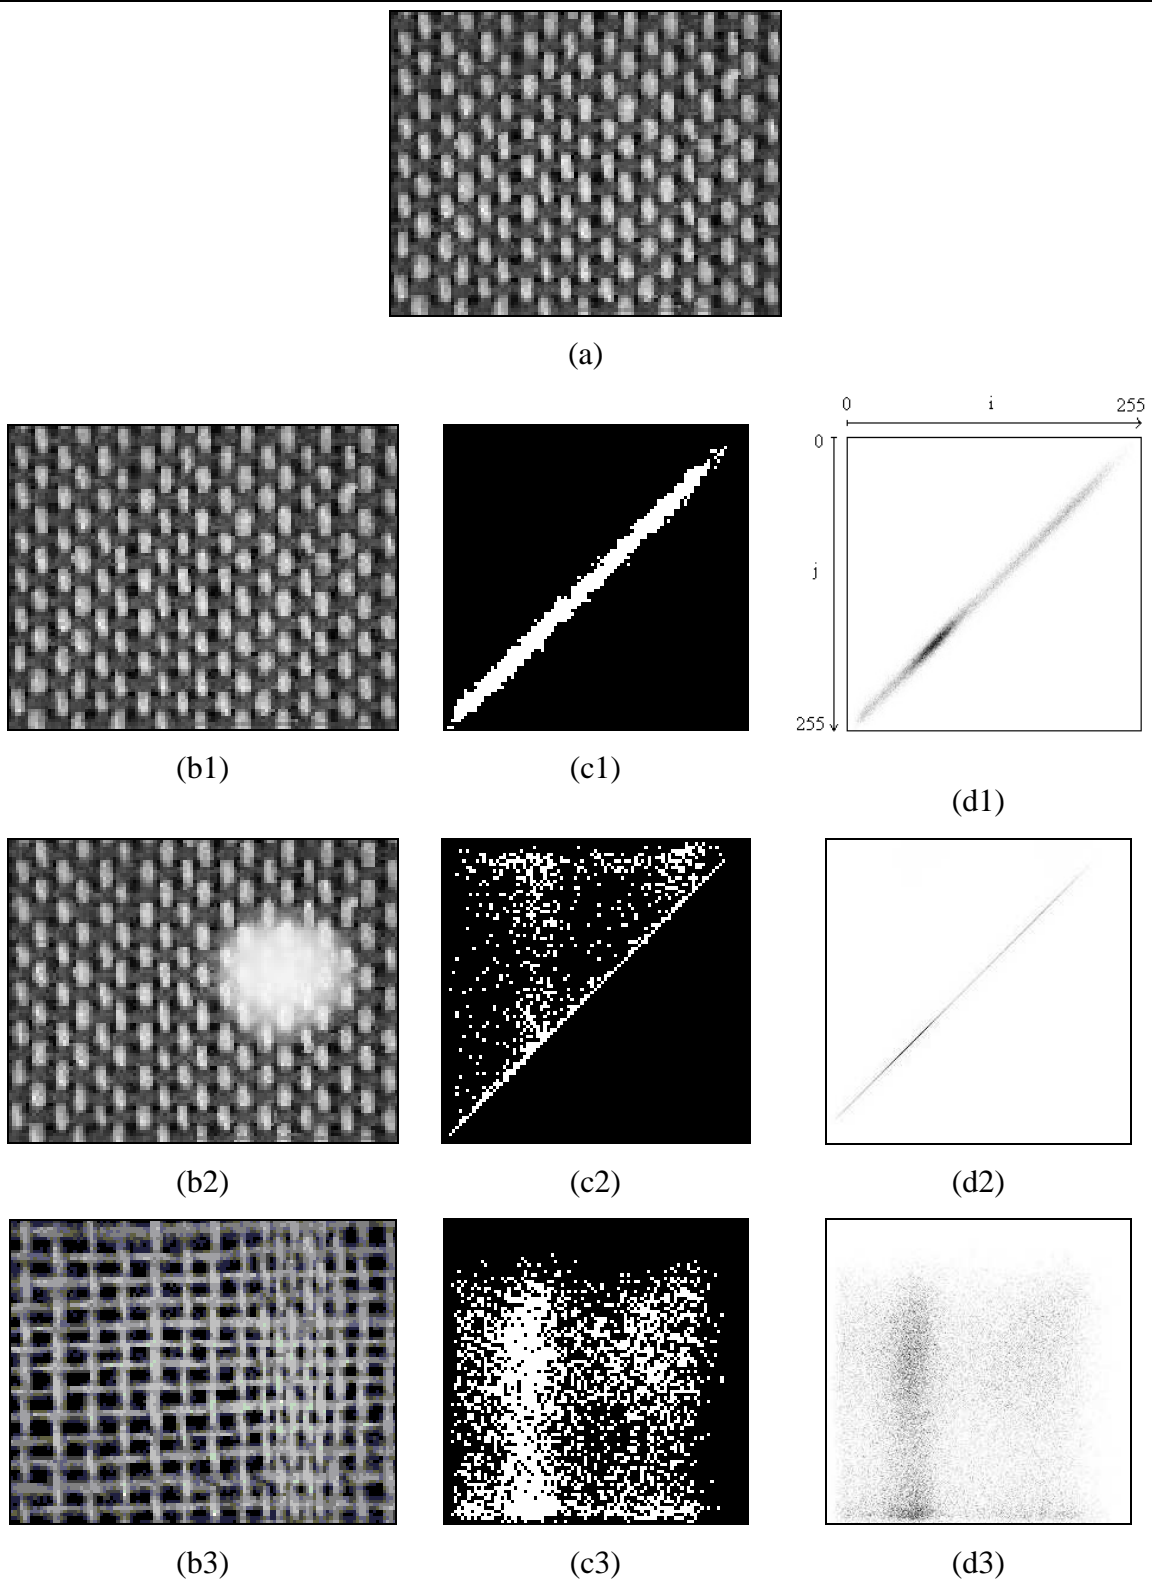
$$C[w(x,y), f(x,y)] = C[w(x,y), f(x,y)] + 1, \quad (2)$$

kde $x = 0, 1, 2, \dots, m-1$ a $y = 0, 1, 2, \dots, n-1$.


Ak dva porovnávané obrázky majú rovnaký obsah v 2D šedoúrovňovej mape podobnosti sa vygeneruje priamka a uhol sklonu čiary reprezentuje zmenu osvetlenia medzi obrázkom a referenčnou šablónou. Odchýlené body od diagonálnej čiary v mape podobnosti odpovedajú chybnnej časti v obrázku.

Príklad porovnania obrázkov, za rovnakých svetelných podmienok, je zobrazený na obr. 7. Pri porovnávaní sa použili obrázky s počtom úrovní šedi 256 a veľkosti 200×156 pixelov. Obr. 7 (a) ukazuje referenčnú šablónu, ktorá sa porovnáva z bezchybným obrázkom obr. 7 (b1), chybným obrázkom obr. 7 (b2) a úplne odlišným obrázkom obr. 7 (b3). Na obr. 7 (c1), (c2), (c3) je zobrazená mapa podobnosti vo forme binárneho obrazu (biela plocha označuje farebnú zhodu u testovaných obrázkoch) a na obr. 7 (d1), (d2), (d3) v úrovniach šedi. Ak sú obrázky úplne zhodné, rozloženie šedých úrovní v mape bude mať tvar diagonálnej priamky obr. 7 (c1). V opačnom prípade, keď dva porovnávané obrázky sú rôzne, to vedie k nelineárnemu tvaru v mape podobnosti obr. 7 (c2). Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom `vlc.m`.

Na obr. 8 je príklad porovnania obrázkov za rôznych svetelných podmienok. Obr. 8 (a) ukazuje referenčnú šablónu a obr. 8 (b1) a (b2) sú preexponované a podexponované verzie kontrolovaného obrázku. Obrázky sú upravené o 1,45 expozičnej hodnoty. Na obr. 8 (c1) a (c2) je zobrazená mapa podobnosti vo forme binárneho obrazu (biela plocha označuje farebnú zhodu u testovaných obrázkoch) a v časti (d1) a (d2) v úrovniach šedi. Z obr. 8 vyplýva, že graf v mape podobnosti je podobný priamke a líši sa v závislosti na svetelných podmienkach. Tučná čiara (spôsobená nerovnomerným osvetlením) so sklonom uhla väčším než 45° je získaná pre preexponovaný obrázok na obr. 8 (c1) a so sklonom uhla menším než 45° je získaná pre podexponovaný obrázok na obr. 8 (c2).



Obr. 7 Mapa podobnosti pre obrázky pri rovnakom osvetlení: (a) referenčná šablóna, (b1) bezchybný obrázok, (b2) chybný obrázok, (b3) odlišný obrázok, (c1) a (d1) výsledok porovnania (a) a (b1), (c2) a (d2) výsledok porovnania (a) a (b2), (c3) a (d3) výsledok porovnania (a) a (b3).



Obr. 8 Mapa podobnosti pre obrázky pri rôznom osvetlení: (a) referenčná šablóna, (b1) preexponovaný obrázok, (b2) podexponovaný obrázok, (c1) a (d1) výsledok porovnania (a) a (b1), (c2) a (d2) výsledok porovnania (a) a (b2).

3.2.2 Metóda porovnania pomocou vlastných čísiel

Podobnosť medzi dvoma porovnávanými obrázkami je odvodená zo štatistických a geometrických vlastností spojená s vlastnými číslami kovariančnej matice v mape podobnosti. Z tejto mapy sa zostaví kovariančná matica a na jej základe sa vypočítajú vlastné čísla.

Kovariančná matica M o veľkosti 2×2 referenčnej šablóny $w(x,y)$ a obrázku $f(x,y)$ o veľkosti $m \times n$, v šedoúrovňovej mape podobnosti, je daná

$$M = \begin{bmatrix} m_{11} & m_{12} \\ m_{21} & m_{22} \end{bmatrix}, \quad (3)$$

kde

$$m_{11} = \left[\frac{1}{m \times n} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f^2(x, y) \right] - (\bar{f})^2,$$

$$m_{22} = \left[\frac{1}{m \times n} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} w^2(x, y) \right] - (\bar{w})^2,$$

$$m_{12} = m_{21} = \left[\frac{1}{m \times n} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x, y) * w(x, y) \right] - (\bar{f} * \bar{w}),$$

kde \bar{f} a \bar{w} sú priemerné hodnoty úrovne šedi obrazu $f(x, y)$ a $w(x, y)$:

$$\bar{f} = \frac{1}{m \times n} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x, y), \quad \bar{w} = \frac{1}{m \times n} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} w(x, y).$$

Existujú dve vlastné čísla λ_L a λ_S pre maticu M :

$$\lambda_L = \frac{1}{2} \left[m_{11} + m_{22} + \sqrt{(m_{11} - m_{22})^2 + 4m_{12}^2} \right], \quad (4)$$

$$\lambda_S = \frac{1}{2} \left[m_{11} + m_{22} - \sqrt{(m_{11} - m_{22})^2 + 4m_{12}^2} \right], \quad (5)$$

a platí $\lambda_L \geq \lambda_S$.

Pomocou týchto vlastných čísiel sa dajú zistiť informácie o šedých úrovniach v mape podobnosti. Väčšie vlastné číslo λ_L predstavuje variabilitu údajov pozdĺž hlavnej osi a menšie vlastné číslo λ_S značí variabilitu údajov pozdĺž vedľajšej osi v mape podobnosti. Ak dva porovnávané obrázky sú rovnaké, tvar priamky v mape podobnosti bude lineárny a menšie vlastné číslo λ_S bude mať nulovú hodnotu. Ak má táto priamka nelineárny tvar, vlastné číslo λ_S bude výrazne väčšie. Preto menšie vlastné číslo λ_S je prijaté ako miera podobnosti.

Tradičná normalizovaná korelácia, ktorá je formulovaná v rovnici (1), môže byť vyjadrená aj pomocou m_{11} , m_{22} a m_{12}

$$\gamma = \frac{m_{12}}{\sqrt{m_{11} \times m_{22}}}. \quad (6)$$

Pri detekcii malých odchýlok v komplikovaných šedoúrovňových obrázkoch výsledky ukázali, že miera podobnosti pomocou vlastného čísla λ_S je lepšia a efektívnejšia ako normalizovaná vzájomná korelácia γ . Pretože obe merania podobnosti λ_S a γ možno vypočítať pomocou rovnice (3), môže sa použiť alternatívna λ_S ako doplnok pre γ pri detekcii chýb – chyba je hlásená, ak odpovedajúca hodnota γ je dostatočne malá alebo hodnota λ_S je dostatočne veľká.

V tabuľke 1 sú uvedené výsledky na porovnanie medzi výslednou normalizovanou korelačnou hodnotou γ a vlastným číslom λ_S z obr. 6, obr. 7 a obr. 8. Z tabuľky vyplýva, že vlastné číslo λ_S je účinným opatrením rozlišovania medzi dvoma porovnávanými obrázkami.

Tab. 1 Výsledné hodnoty vlastných čísiel λ_S a korelačných koeficientov γ z obr. 6, obr. 7 a obr. 8.

Porovnávané obrázky	Miery podobnosti	
	γ	λ_S
Obr. 6 (a1) a (b1)	0,999	0,73
Obr. 6 (a1) a (c1)	0,941	417,37
Obr. 7 (a) a (b1)	0,997	8,98
Obr. 7 (a) a (b2)	0,812	625,65
Obr. 7 (a) a (b3)	0,045	2905,30
Obr. 8 (a) a (b1)	0,985	53,42
Obr. 8 (a) a (b2)	0,999	0,31


3.3 Latentné sémantické indexovanie

S nárastom informačných technológií, vzniká obrovské množstvo multimediálnych údajov (textové, obrazové, zvukové dokumenty). Tieto údaje je treba vhodne reprezentovať a organizovať, aby v nich išlo vyhľadávanie rýchlo a ľahko. Jednotlivé multimediálne dokumenty sa reprezentujú vektormi vo vysoko dimenzionálnom prostredí. Často sa používa sekvenčný spôsob vyhľadávania, kedy je celá kolekcia dokumentov (kolekcia vektorov) postupne sekvenčne načítaná a hľadané dokumenty sa vyhľadávajú pomocou vzájomného porovnávania všetkých dokumentov v kolekcii s dotazovaným dokumentom. Takýto spôsob ale nie je v súčasnej dobe vhodný, lebo kolekcie dokumentov sú veľmi rozsiahle a sekvenčný priechod takouto kolekciou by trval príliš dlho. Preto boli navrhnuté metódy, ktoré najprv kolekciu predspracujú do vopred navrhnutej štruktúry – indexu [2], [3], [7], [14].

Indexovanie je spracovanie údajov do databázy. Cieľom indexovania je umožniť rýchle vyhodnotenie užívateľského dotazu pomocou indexu.

3.3.1 Extrakcia vlastností pomocou metódy *LSI*

Pre extrakciu vlastností obrázku existuje celá rada metód. Jednou z nich je metóda latentné sémantické indexovanie *LSI* (*Latent Semantic Indexing*). Ide o metódu, kedy je celý obrázok veľkosti $x \times y$ (úrovne šedi) prevedený na vektor dimenzie $x \times y$. Transformácia obrázka do vektoru sa prevádza jednoducho. Riadky obrázka sa „naskladajú“ za seba, čím vznikne vysoko dimenzionálny „jasový“ vektor. Nejedná sa ešte o extrakciu vlastností, podľa ktorých by sa dalo vyhľadávať obrázky. Vďaka tomu, že obrázky sú reprezentované jasovými vektormi, sa môže celá kolekcia obrázkov (o veľkosti n) prezentovať maticou A poľa $x \times y \times n$. Jednotlivé vektory obrázka tvoria stĺpce matice na obr. 9.



Obr. 9 Transformácia obrázka do vektora jasu a umiestnenie do matice A .

3.3.2 Klasická metóda *LSI* ako rozšírenie vektorového modelu

V oblasti dokumentografických informačných systémov *DIS* sa s modelom *LSI* stretávame v kontexte reprezentácie a indexovania textových dokumentov vo vektorovom modeli. Textová kolekcia obsahuje spolu m unikátnych vzťahov, pričom m -rozmerné vektory dokumentov (stĺpce matice A) reprezentujú váhy jednotlivých vzťahov v textových dokumentoch. Pomocou singulárneho rozkladu *SVD* (*Singular Value Decomposition*) matice A


$$A = U \Sigma V^T, \quad (7)$$

sa v textovej kolekcii nájdú vektory konceptu (ľavé singulárne vektory – stĺpce v matici U), ktoré možno interpretovať ako jednotlivé témy prítomné v kolekcii. Dôležitou vlastnosťou singulárneho rozkladu je, že vektory konceptov sú usporiadané podľa „dôležitosti“ (dôležitosť vyjadrujú hodnoty singulárnych čísiel uložené postupne vo vzostupnom poradí v diagonálnej matici Σ) – podľa toho, v akej miere a v koľkých dokumentoch sa (ne)vyskytujú. Tým sa určí, ktoré koncepty sú vzhľadom ku kolekcii sémanticky dôležité a tie, ktoré sú nepotrebné, pôsobia ako sémanticky šum. Stĺpce matice ΣV^T obsahujú vektory dokumentov (vektorové pseudo–dokumenty), ktoré sú teraz vyjadrené v báze U (v báze konceptov).

Keďže iba prvých k konceptov možno považovať za sémanticky dôležité (príslušné singulárne čísla sú vysoké), môžeme pôvodný rozklad aproximovať ako

$$A \approx U_k \Sigma_k V_k^T, \quad (8)$$

kde v U_k je prvých k najdôležitejších vektorov konceptov, v Σ_k sú príslušné singulárne čísla a v $\Sigma_k V_k^T$ vektory pseudo - dokumenty vyjadrené pomocou prvých k vektorov konceptov, ako to je zobrazené na obr. 10.



Obr. 10 Aproximácia SVD rozkladu.


U je ortogonálna matica o veľkosti $m \times k$, ktorej stĺpce definujú ľavé singulárne rozklady matice A , T je ortogonálna matica o veľkosti $k \times n$, ktorej stĺpce definujú pravé singulárne vektory A . Σ je diagonálna matica o veľkosti $k \times k$ obsahujúca singulárne čísla usporiadané zostupne na hlavnej diagonále.

SVD premieta pôvodné m – rozmerné vektory dokumentov do priestoru dimenzie k ($k \ll m$). Aproximácia *SVD* rozkladu matice A ide dosiahnuť tak, že buď prevedieme úplný *SVD* rozklad a potom príslušné matice „orežeme“, alebo zvolíme niektorú z časovo menej náročných numerických metód, ktorá počíta priamo redukovaný rozklad. Ak chceme v kolekcii dokumentov vyhľadávať, porovnávame vektory pseudo–dokumentov s vektorom pseudo–dotazom na základe určitej miery podobnosti (kosínusová miera, ktorá sa používa v klasickom vektorovom modeli, ako je *LSI*), t.j.

$$\cos \theta = \frac{(x, y)}{\sqrt{(x, y)}\sqrt{(x, y)}}. \quad (9)$$

Kosínusová vzdialenosť je uhol dvoch vektorov vyjadrená pomocou skalárneho súčinu vektorov x a y . Slúži na získanie geometrickej predstavy vzdialenosti medzi dvoma vektormi. Kosínusová miera je v rozsahu $-1 \leq \cos \theta \leq 1$. Touto mierou sa počíta kosínus uhlu, ktorý zvierá vektor dotazu s vektorom dokumentu. Čím je táto miera väčšia, tým je uhol menší, t.j. tým „bližšie“ a viac podobné sú oba vektory. Podobnosť vo vektorovom modeli možno chápať ako vzdialenosť jednotlivých vektorov dokumentu vo vektorovom prostredí [12], [13].

Na obr. 11 je význam kosínusovej vzdialenosti pre podobnosť vektorov dokumentov v 2D priestore. Vektory dokumentov sú zobrazené ako body so súradnicami ich koncových bodov. Dokumenty relevantné k dotazu užívateľa sú všetky dokumenty, ktoré zvierajú s dotazovacím vektorom q uhol $\leq \theta$. Symboly A , B , Q reprezentujú vektory (dokumenty). Symboly φ_A a φ_B označujú uhly medzi A , Q , a B , Q .



Obr. 11 Kosínusová vzdialenosť dotazovacieho vektoru a vektoru dokumentov v 2D priestore.

Výhoda vektorového modelu je v tom, že užívateľ na výstupe dostane zotriedené relevantné dokumenty podľa ich vzdialeností od dotazovaného vektora.

3.3.3 LSI pre kolekciu obrázkov

Vzhľadom k tomu, že *SVD* rozklad možno aplikovať na ľubovoľnú maticu, je možno model *LSI* aplikovať na ľubovoľné typy údajov. Obecné je možné model *LSI* adaptovať pre indexovanie ľubovoľnej multimediálnej kolekcie, ktorú možno reprezentovať súborom vektorov zhodnej dimenzie. Jedinou podmienkou je zostavenie matice A tak, aby vektory vlastností dokumentov tvorili stĺpce. Pomocou *SVD* maticu A rozložíme rovnako ako pri klasickom použití *LSI* – získame aproximáciu rozkladu $A \approx U_k \Sigma_k V_k^T$. Vhodnou kombináciou básových obrázkov vznikne ľubovoľný obrázok z kolekcie (čím vyššie k , tým presnejšia rekonštrukcia obrázku).

3.3.3.1 Rekonštrukcia obrázka

Pre vizuálnu predstavu, aké veľké (alebo malé) k je postačujúce pre popis obsahu obrázka, sa obrázky spätne rekonštruujú tak, že pre dané k sa urobí rozklad a matica A sa rekonštruje ako $A \approx U_k \Sigma_k V_k^T$.

Pre veľmi malé k je rekonštrukcia obrázka veľmi nedokonalá. Čím vyššie k , tým je rekonštrukcia dokonalejšia, ide rozoznať prítomnosť niektorých hrubých detailov alebo je rekonštrukcia na takej úrovni, že pôvodné objekty ide jednoznačne rozoznať. Z toho vyplýva, že ak bude treba vyhľadávať v kolekcii obrázkov podľa hrubých obrysův, bude výhodnejšie použiť len niekoľko málo súradníc vektorov pseudo-obrázkov. Naopak v prípade, že sa budú vyhľadávať objekty podľa detailov, zvolí sa väčší počet súradníc – vyššie k .

3.3.4 Miera podobnosti pre porovnávanie obrázkov

Po prevedení *SVD* rozkladu dostaneme kolekciu vektorov pseudo-obrázkov, ktoré je treba porovnať s vektorom pseudo-dotazom. Obecné sa v oblasti vyhľadávania v obrazových kolekciiach používa mnoho najrôznejších mier podobností.

Miera schopnosti poskytnúť užívateľovi informácie o relatívnych dokumentoch sa vyjadruje pomocou koeficientu presnosti (možno chápať ako pravdepodobnosť, že vybraný dokument je relevantný) a koeficientu úplnosti (pravdepodobnosť, s akou boli vybrané

všetky relatívne dokumenty). V ideálnom prípade sú tieto koeficienty presnosti a úplnosti rovné 1. Ale tento stav nemožno dosiahnuť. Koeficienty sú navzájom závislé (s rastúcou presnosťou klesá úplnosť a naopak) [7].

V prípade modelovania obrázka vektorom pseudo-obrázka sú súradnice nekorelované (súradnice obsahujú váhy vektorov konceptov, ktoré tvoria bázu a sú lineárne nekorelované), stačí, keď použijeme pre porovnanie vektorov obyčajnú Euklidovu vzdialenosť alebo inú Minkowského metriku. Modelovaná podobnosť podľa vzdialenosti je interpretovaná tak, že čím vzdialenejšie sú oba vektory, tým menej sú si podobné obrázky. Nulovú vzdialenosť majú identické obrázky (ich vektory). Výhoda Euklidovskej vzdialenosti spočíva v tom, že je to metrika, a preto ide celú kolekciu obrázkov indexovať pomocou metrických prístupových metód, čo umožňuje v kolekcii rýchle vyhľadávanie. Rýchlosť vyhľadávania je daná dvoma faktormi spotrebovaných behom vyhodnocovania dotazov. Jednak je to počet diskových prístupov a jednak počet aplikácií danej metriky (množstvo výpočtov vzdialeností).

4 Testovacia obrazová sada

Pri testovaní mier podobnosti bola vybraná testovacia obrazová sada textúr textílií a textilných vzorov. Táto testovacia obrazová sada obsahuje:

- 20 naskenovaných tkanín
- 2 naskenované tkaniny natočené v 4 rôznych smeroch
- databázu textúr textílií a textilných vzorov

4.1 Naskenované tkaniny

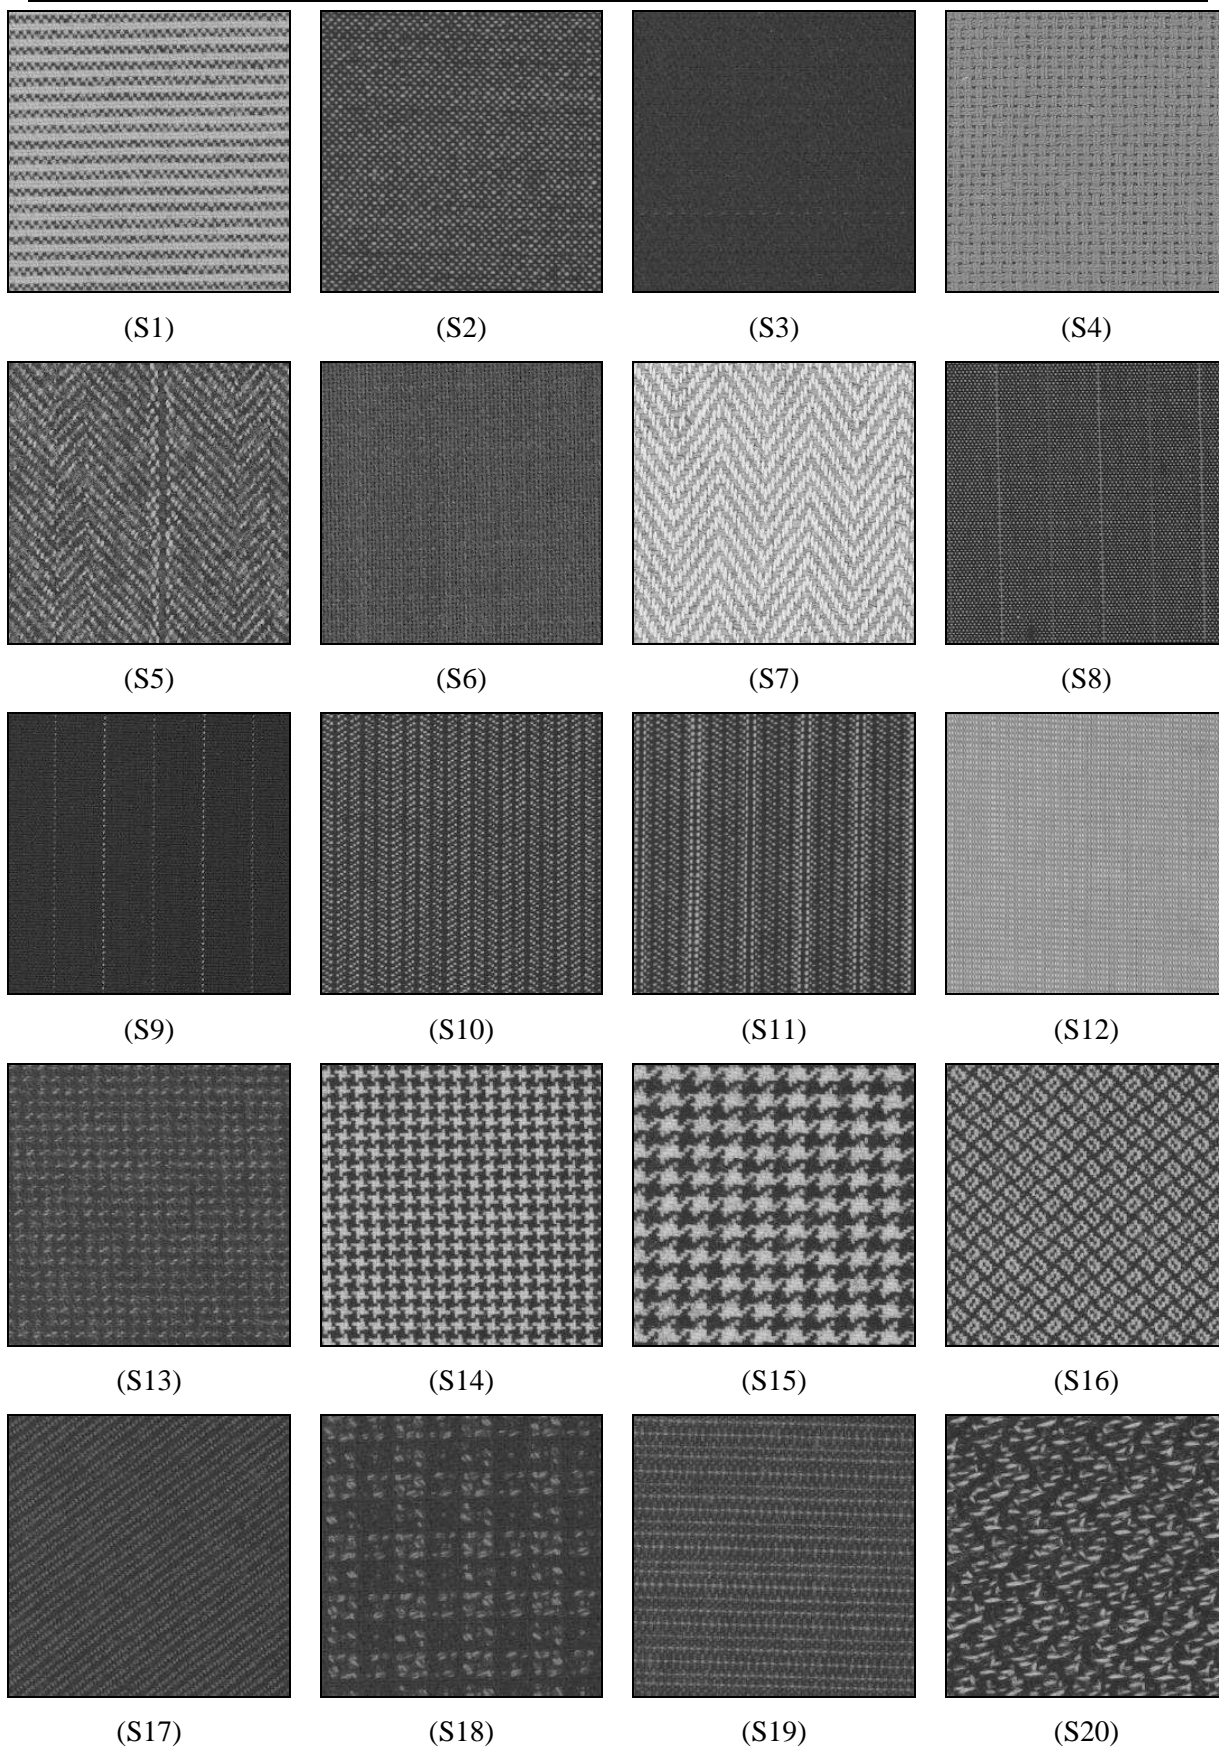
Na testovanie sa použilo 20 naskenovaných tkanín s rôznou väzbou – plátno, keper, atlas. Tieto tkaniny boli nasnímané s rozlíšením 200 dpi v úrovni šedi. Sú uložené vo formáte *bmp* a budú značené písmenom S. Na obr. 12 (S1) – (S20) je zobrazená kolekcia naskenovaných tkanín.

4.2 Naskenované tkaniny v 4 rôznych smeroch


Z 20 naskenovaných tkanín boli vybrané 2 tkaniny obr. 12 (S15) a (S17), ktoré sa naskenovali v 4 rôznych smeroch o určitom uhle. Tieto tkaniny sa nasnímali v úrovni šedi s rozlíšením 200 dpi a sú uložené vo formáte *bmp*. Na obr. 13 (R15-r1) – (R15-r4) sú vidieť štyri rôzne smery pootočenia prvej tkaniny a na obr. 13 (R17-r1) – (R17-r4) druhej vybranej tkaniny.

4.3 Databáza textúr textílií a textilných vzorov

Obrázky označené písmenom D pochádzajú z databázy textúr. Táto databáza je dostupná v Univerzitnom E-Learningovom Systéme [9]. Zvolili sa obrázky tkanín rôznej väzby a netkaných textílií. Spolu bolo vybraných 364 obrázkov o veľkosti 1232×964 pixelov, ktoré boli zmenšené na veľkosť 700×548 pixelov. Obrázky sú prevedené do úrovni šedi a uložené vo formáte *bmp*.



Obr. 12 (S1) - (S20) Kolekcia naskenovaných tkanín.



Obr. 13 (R15-r1) – (R15-r4) Rôzne smery pootočenia prvej tkaniny, (R17-r1) – (R17-r4) rôzne smery pootočenia druhej tkaniny.


4.4 Testovacia sada 1

Z 20 naskenovaných tkanín sa vybrala jedna tkanina, ktorá sa porovnávala s touto kolekciou naskenovaných tkanín. Zisťovala sa miera podobnosti medzi dotazovanou tkaninou a kolekciou naskenovaných tkanín. Pri pokuse bola použitá metóda *LSI*. Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom `lsi_01.m`.


Na obr. 14 (S14) je príklad jednej tkaniny vybranej z kolekcie naskenovaných tkanín pri použití rôzneho k . Obr. 14 (a1) – (a10) znázorňuje rekonštrukciu obrázku vyhlľadanej tkaniny. Na grafoch možno vidieť jednotlivé miery podobnosti dotazovanej tkaniny s kolekciou naskenovaných tkanín. *Sim* v grafe označuje mieru podobnosti a T_i značí jednotlivé tkaniny z kolekcie. Veľkosť výrezu bola nastavená na 250×250 pixelov.

Na obr. 14 (a1) pri hodnote $k = 1$ je vidieť, že rekonštrukcia tkaniny je veľmi nedokonalá. Pri $k = 2$ je rekonštrukcia lepšia obr. 14 (a2), idú rozoznať niektoré hrubé


detaily. Od $k = 3$ a vyššie je rekonštrukcia dokonalejšia. Je dobre vidieť štruktúru tkaniny. Čím je vyššie k , tým je presnejšia rekonštrukcia obrázku. Výsledky pre rôzne tkaniny ukázali, že najvhodnejšie k je pri hodnote 20 a vyššie.




(S14)




$k = 1$





(a1)



$k = 2$





(a2)





(a3)

$k = 3$




(a4)

$k = 5$




(a5)


$k = 7$




$k = 10$




(a6)




$k = 13$




(a7)




$k = 17$




(a8)




$k = 20$



(a9)




$k = 50$



(a10)

Obr. 14 (S14) Dotazovaná tkanina, (a1) - (a10) vyhládaná tkanina, grafy *sim*.


Príklad 3 vybraných tkanín z kolekcie naskenovaných tkanín je na obr. 15. Na základe výsledkov sa tkaniny testovali pri hodnote $k = 20$. Obr. 15 (S) zobrazuje dotazovanú tkaninu. Obr. 15 (a) – (c) znázorňuje rekonštrukciu obrázku vyhládenej tkaniny. Na grafoch možno vidieť jednotlivé miery podobnosti dotazovanej tkaniny s kolekciou naskenovaných tkanín. *Sim* v grafe označuje mieru podobnosti a T_i značí jednotlivé tkaniny z kolekcie. Veľkosť výrezu bola nastavená na 250×250 pixelov. Ďalšie príklady sú uvedené v prílohe č. 2.




Obr. 15 (S) dotazovaná tkanina, (a) – (c) vyhl'adaná tkanina, grafy *sim*.

Na obr. 16 je príklad vybranej jednej tkaniny naskenovanej v jednom smere. Obr. (R15-r4) zobrazuje dotazovanú tkaninu a na obr. 16 (a) je rekonštrukcia obrázku vyhl'adanej tkaniny. Na obrázku je vidieť, že sa nevyhl'adala podobná tkanina. Testovanie sa robilo pri hodnote $k = 20$ na základe predchádzajúcich výsledkov. Veľkosť výrezu bola nastavená na 250×250 pixelov.


Použitie metódy *LSI* na takejto tkanine nie je vhodné. Metóda je citlivá na rotáciu obrazu alebo vzoru v obraze. V dôsledku tohto zistenia bolo prevedené ďalšie testovanie, pri ktorom sa použilo natáčanie obrazu, vid' kapitola 4.5.



(R15-r4)



$$k = 20$$




(a)

Obr. 16 (R15-r4) dotazovaná tkanina, (a) vyhl'adaná tkanina, grafy *sim*.

4.5 Testovacia sada 2



Pokus, ktorý sa prevádzal na 2 tkaninách naskenovaných v rôznych smeroch, sa testoval pri veľkosti výrezu 200×200 pixelov a pri hodnote $k = 20$ na základe predchádzajúcich testov. Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom `rotacia.m`.

Na obr. 17 je príklad tkaniny a jej pootočené s krokom 9° v rozsahu od -90° do 90° stupňov. Pokus sa testoval pri veľkosti výrezu 200×200 pixelov pri hodnote $k = 20$. Po načítaní tkaniny sa najprv urobil kruhový výrez (hodnoty úrovni šedi mimo kruh boli nastavené na 0), pre ľahšie pracovanie s tkaninou. Tkanina sa natáčala postupne od -90° po 90° s krokom 9° . Jednotlivé natočené obrazy tkaniny sa ukladajú do databázy, kde stĺpce predstavujú obrazy tkaniny natočených pod určitým uhlom, ktorá sa porovnáva s dotazovanou tkaninou.





Obr. 17 (o1) - (o20) Natáčanie tkaniny v uhle od -90° po 90° .

Na obr. 18 (R15-r4) a (R17-r4) sú zobrazené 2 tkaniny naskenované v rôznom smere. Tkanina sa otáčala od -90° po 90° s krokom 1° . Veľkosť výrezu bola nastavená na 200×200 pixelov pri hodnote $k = 20$. Na grafoch možno vidieť mieru podobnosti dotazovanej tkaniny pri uhloch natáčania. *Sim* v grafe označuje mieru podobnosti a $U[^\circ]$ pracovne označuje uhol pootočenia tkaniny v stupňoch. Z výsledkov vyplýva, že najväčšia miera podobnosti je pri uhle 0° . Dochádza k periodicite.



(R15-r4)





(R17-r4)



Obr. 18 (R15-r4) a (R17-r4) Tkanina naskenovaná v rôznom smere, grafy *sim*.

Pokus sa prevádzal aj na kolekcii naskenovaných tkanín. Veľkosť výrezu bola nastavená na 200×200 pixelov s hodnotou $k = 20$. Na grafe u tkaniny na obr. 19 (S14) je vidieť, že dotazovaná tkanina má najväčšiu mieru podobnosti v 0° a pri 90° sa miera podobnosti blíži k 1, dochádza k symetrii. Na obr. 19 (S1) je príklad tkaniny, ktorá má

najväčšiu mieru podobnosti len v 0° . Dochádza u nej k periodicite. Ďalšie príklady sú uvedené v prílohe č. 3.



(S1)



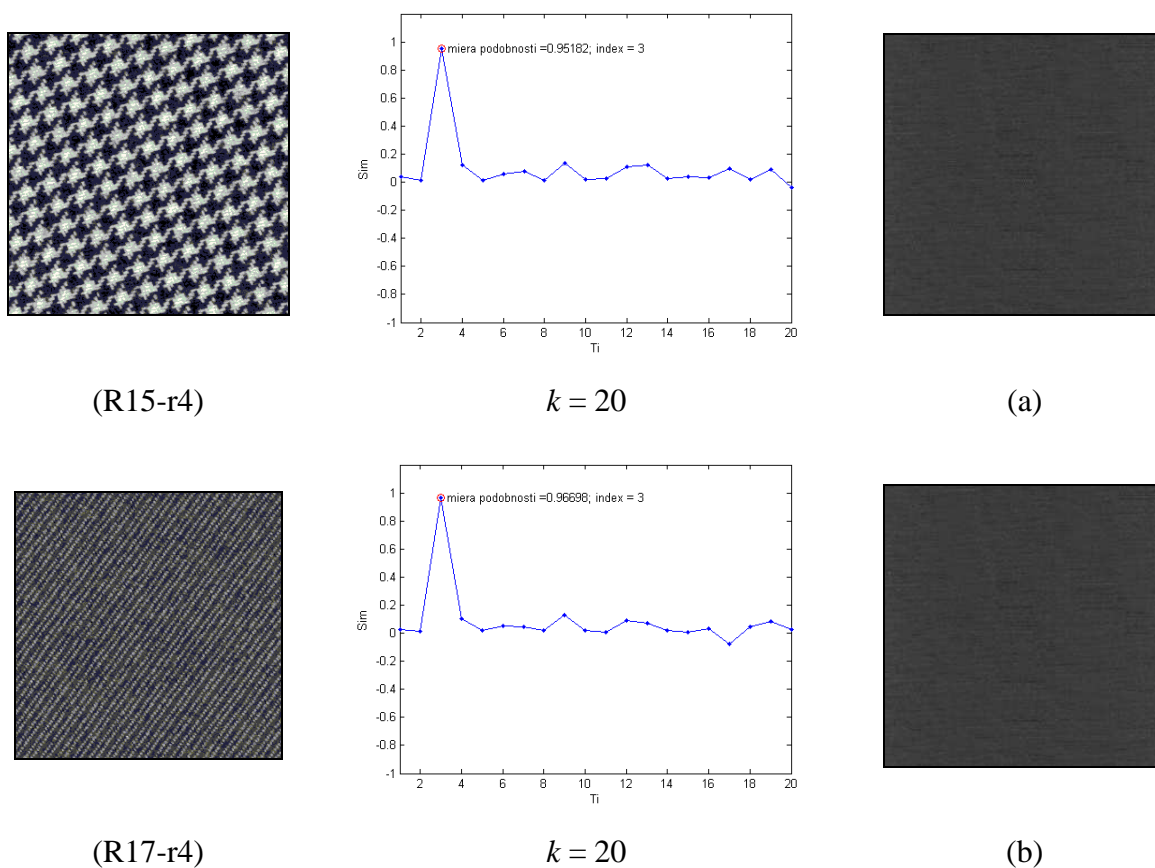
(S14)

Obr. 19 (S1) a (S14) Dotazovaná tkanina, grafy *sim*.

Následne sa otáčanie obrazu aplikovalo v metóde *LSI*. Dochádza k porovnávaniu natáčaných obrazov dotazovanej tkaniny pri rôznom uhle s obrazmi tkanín z kolekcie. Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom *lsi_rot.m*.

Na obr. 20(R15-r4) a (R17-r4) je príklad dvoch tkanín naskenovaných v rôznom smere. Dotazovaná tkanina je natáčaná v uhle od -25° do 25° s krokom 1° . Natáčané obrázky tkaniny sa ukladajú do matice, kde stĺpce predstavujú jednotlivé tkaniny a riadky predstavujú uhly pootočenia. Graf je zostrojený pri konkrétnom uhle pootočenia, kde bola nájdená najväčšia miera podobnosti. Veľkosť výrezu bola nastavená na 200×200 pixelov pri hodnote $k = 20$. Na obr. 20 (a) a (b) je výsledná tkanina vyhl'adaná v kolekcii tkanín. Na grafoch možno vidieť jednotlivé miery podobnosti natáčaných obrazov dotazovanej tkaniny s kolekciiu tkanín pri hodnote $k = 20$. *Sim* označuje mieru podobnosti a T_i značí jednotlivé tkaniny z kolekcie.

Z výsledkov vyplýva, že ani toto pootočené obrázok nie je vhodné pri vyhľadávaní takýchto natočených tkanín. V dôsledku tohto zistenia bolo prevedené ďalšie testovanie, pri ktorom sa použilo výkonové spektrum obrázku získané z 2D Fourierovej transformácie, viď kapitola 5.1.1.



Obr. 20 (R15-r4) a (R17-r4) Tkanina naskenovaná v rôznom smere, (a) a (b) vyhľadaná tkanina, graf *sim* (R15-r4) pre uhol -14° a (R17-r4) pre uhol -15° .

4.6 Testovacia sada 3

Testovanie sa prevádzalo v databáze textúr textílií a textilných vzorov, kde sa vybrali 4 plošné textílie – 2 tkaniny a 2 netkané textílie. Tieto textílie sa testovali metódou *LSI*. Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom `lsi_01.m`.

Veľkosť výrezu bola nastavená na 150×150 pixelov. Na základe predchádzajúcich výsledkov sa textílie testovali pri hodnote $k = 7, 10, 13, 20, 50, 150, 250$.


Na obr. 21 (D294) je príklad netkanej textílie náhodne vybranej z databázy textúr. Obr. 21 (a) zobrazuje rekonštrukciu obrázku vyhľadanej textílie. Pre malé $k = 7$ je rekonštrukcia veľmi nedokonalá ako je vidieť na obr. 21 (a1). Pre $k = 50$ je rekonštrukcia lepšia obr. 21 (a2), idú rozoznať niektoré hrubé detaily. V prípade $k = 250$ je rekonštrukcia obrázku dokonalejšia obr. 21 (a3), ostrejšia. Je dobre vidieť štruktúru textílie. Z výsledkov vyplýva, že ak chceme vyhľadávať v databáze textúr textílie podľa detailov, zvolí sa vyššie k .

Na obr. 22 (D5), obr. 23 (D38), a obr. 24 (D318) sú príklady tkanín a netkaných textílií náhodne vybraných z databázy textúr pri hodnote $k = 20$. Obr. 22 (a1), obr. 23 (a1) a obr. 24 (a1) zobrazuje rekonštrukciu obrázka nájdenej podobnej textílie. Na grafoch možno vidieť jednotlivé miery podobnosti dotazovanej textílie s textíliami z databázy textúr. *Sim* v grafe označuje mieru podobnosti a T_i značí jednotlivé textílie z databázy.


Obr. 22 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D9, D8, D3, D277, D4, D15. Na obrázkoch je vidieť, že boli nájdené textílie podobnej štruktúry. Ďalšie príklady sú uvedené v prílohe č.4.

Obr. 23 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D32, D169, D358, D35, D325, D300. Ďalšie príklady sú uvedené v prílohe č.4.


Obr. 24 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D112, D60, D113, D273, D322, D228. Ďalšie príklady sú uvedené v prílohe č.4.




(D294)




$k = 7$




(a1)




$k = 50$



(a2)




$k = 250$




(a3)


Obr. 21 (D294) Dotazovaná netkaná textília, (a1) – (a3) vyhl'adaná textília, grafy *sim*.




(D5)




$k = 20$




(a1)




(v1)




(v2)




(v3)



(v4)




(v5)




(v6)


Obr. 22 (D5) Dotazovaná tkanina, (a1) vyhládaná textília, (v1) – (v6) podobná textília, graf *sim.*



(D38)




$k = 20$




(a1)




(v1)




(v2)




(v3)



(v4)




(v5)




(v6)


Obr. 23 (D38) Dotazovaná tkanina, (a1) vyhládaná textília, (v1) – (v6) podobná textília, graf *sim*.




(D318)




$k = 20$




(a1)




(v1)




(v2)




(v3)



(v4)



(v5)



(v6)

Obr. 24 (D318) Dotazovaná netkaná textília, (a1) vyhládaná textília, (v1) – (v6) podobná textília, graf *sim*.

5 Dvojrozmerná diskretná Fourierová transformácia

Medzi spektrálne techniky patrí dvojrozmerná diskretná Fourierová transformácia *2D DFT* (*2 Dimensional Discrete Fourier Transforms*). Tieto techniky pomocou frekvenčnej oblasti popisujú textúry. Sú založené na vlastnostiach Fourierovho obrazu spektra a popisujú globálnu periodicitu úrovne šedi obrazu identifikovaním vysokých frekvenčných hodnôt v spektre. Fourierove spektrum je vhodné pre popis smerovania periodických alebo takmer periodických vzorov v monochromatických obrazoch textúr. Smerový charakter monochromatických obrazov jasne korešponduje s vysokými hodnotami frekvenčných komponentov, ktoré sú rozložené pozdĺž priamych smerov v obraze spektra. Navrhovaná grafická metóda je založená na použití obrazovej analýzy so spektrálnym prístupom. Výhodou metódy je jej rýchlosť.

Nech $f(x,y)$ je obrazová funkcia pre $x = 0,1,2, \dots, m-1$ a $y = 0,1,2, \dots, n-1$, kde $m \times n$ je veľkosť obrazu. *2D DFT* [5] obrazovej funkcie $f(x,y)$ je daná vzťahom:

$$F(u,v) = \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} f(x,y) e^{-j2\pi(ux/m + vy/n)}, \quad (10)$$

pre $u = 0,1,2, \dots, m-1$ a $v = 0,1,2, \dots, n-1$. Frekvenčná oblasť je súradný systém s frekvenčnými premennými u a v . Podobne je definovaná priestorová oblasť so súradným systémom s priestorovými premennými x a y . Pravouhlá oblasť $m \times n$ definovaná pomocou $u = 0,1,2, \dots, m-1$ a $v = 0,1,2, \dots, n-1$ je nazývaná ako frekvenčný pravouholník. Tento frekvenčný pravouholník má rovnaký rozmer ako vstupný obraz. Inverzná diskretná Fourierová transformácia *2D IFT* (*2 Dimensional Inverse Fourier Transforms*) má tvar:

$$f(x,y) = \frac{1}{m \times n} \sum_{x=0}^{m-1} \sum_{y=0}^{n-1} F(u,v) e^{-j2\pi(ux/m + vy/n)}, \quad (11)$$

pre $x = 0,1,2, \dots, m-1$ a $y = 0,1,2, \dots, n-1$. Keď je daná $F(u,v)$ pomocou *IFT* získa sa $f(x,y)$. Funkčné hodnoty $F(u,v)$ sa nazývajú Fourierové koeficienty rozvoja. Hodnota transformácie v počiatku frekvenčnej oblasti $F(0,0)$ sa nazýva *DC* komponentu Fourierovej transformácie (*DC – Direct Current*). Ak $f(x,y)$ je reálna funkcia, jej transformácia je funkcia komplexná. Z dôvodu vizuálnej analýzy transformácie je dobré vypočítať jej

spektrum a zobrazit' ako obraz. Nech $R(u, v)$ a $I(u, v)$ reprezentujú reálnu a imaginárnu časť $F(u, v)$. Amplitúdové frekvenčné spektrum je definované ako:

$$|F(x, y)| = \sqrt{R^2(u, v) + I^2(u, v)}. \quad (12)$$

Výkonové spektrum je definované ako:

$$P(u, v) = |F(x, y)|^2 = R^2(u, v) + I^2(u, v). \quad (13)$$

Pre vizuálne zobrazenie je jedno či sa zobrazuje $|F(x, y)|$ alebo $P(u, v)$. Pretože dynamický rozsah hodnôt spektra je príliš veľký, preto je pre $P(u, v)$ v škále úrovni šedi v 8 – bitovej hĺbke prevedená logaritmická transformácia. Logaritmická transformácia je definovaná:


$$P(u, v) = \log(1 + |F(x, y)|^2). \quad (14)$$

Myšlienkou 2D Fourierovej transformácie obrazu je výkonové spektrum, kde sa pomocou metódy *LSI* tieto spektrá tkaniny porovnávajú.

5.1 Testovacia sada 4 - vyhodnotenie metódy *LSI* pomocou 2D *DFT*

Experiment sa prevádzal na testovacej obrazovej sade pomocou 2D *DFT*. Porovnáva sa výkonové spektrum dotazovanej tkaniny s výkonovými spektrami tkanín z kolekcie. Obraz dotazovanej tkaniny sa natáča v uhlovom rozmedzí od -25° po 25° s krokom 1° . Pre každý natočený obraz je vytvorené (vypočítané) odpovedajúce výkonové spektrum a je porovnávaný na základe metódy *LSI* s maticou dokumentov, ktorá obsahuje výkonové spektrá jednotlivých tkanín. Výsledkom je matica miery podobnosti *sim*, kde riadky matice predstavujú uhol natočenia dotazovanej tkaniny a stĺpce jednotlivé tkaniny. Prvky v matici predstavujú kosínusovú mieru podobnosti. Nájdením maxima v tejto matici je možné identifikovať najpodobnejšiu tkaninu a uhol jej natočenia. Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom `lsi_FT.m`.

Na obr. 25 je príklad postupného natáčania dotazovanej tkaniny a jej výkonového spektra v uhle od -2° do 2° s krokom 1° . Veľkosť výrezu bola nastavená na 100×100 pixelov pri hodnote $k = 20$. Obr. 25 (o1) znázorňuje tkaninu natočenú v smere o jeden stupeň a na obr. 25 (s1) je znázornené výkonové spektrum, tejto tkaniny, natočené v tom istom smere ako je tkanina na obr. 25 (o1).




Obr. 25 (o1) – (o5) Natáčanie tkaniny v uhle od -2° do 2° , (s1) – (s5) natočené výkonové spektrum tkaniny.

5.1.1 Naskenované tkaniny v rôznych smeroch

Táto metóda porovnáva kolekciu naskenovaných tkanín s dvomi naskenovanými tkaninami v rôznych smeroch.

Na obr. 26 (R15-r1), obr. 27 (R15-r2), obr. 28 (R15-r3) a obr. 29 (R15-r4) sú príklady prvej tkaniny naskenovanej v 4 rôznych smeroch. Tkaniny sa testovali pri rôznej hodnote k . Výsledky merania ukázali, že najväčšia miera podobnosti u týchto tkanín je pri použití hodnoty $k = 8$, kde sa zhoduje dotazovaná tkanina s nájdenou tkaninou z kolekcie tkanín. U tkaniny na obr. 29 (R15-r4) je ale najväčšia miera podobnosti pri hodnote $k = 16$. Obr. 26 (a1), obr. 27 (a1), obr. 28 (a1) a obr. 29 (a1) zobrazuje nájdené podobné tkaniny.


Na obr. 26 je príklad tkaniny naskenovanej v jednom smere. Dotazovaná tkanina je natáčaná v uhle od -25° do 25° s krokom 1° . Veľkosť výrezu bola nastavená na 100×100 pixelov pri rôznej hodnote k . Obr. 26 (R15-r1) znázorňuje pootočenú naskenovanú tkaninu v úrovni šedi, ktorá je porovnávaná s kolekciou naskenovaných tkanín. Na grafoch možno vidieť jednotlivé miery podobnosti výkonových spektier dotazovanej tkaniny s kolekciou tkanín pri rôznej hodnote k . Tieto grafy boli zostrojené pri konkrétnom uhle pootočenia, kde bola miera podobnosti najväčšia. Sim označuje mieru podobnosti a T_i značí jednotlivé tkaniny z kolekcie. Červený krúžok označuje maximálnu hodnotu nájdenia miery podobnosti. Na obr. 26 (a1) je vyhládaná podobná tkanina z kolekcie tkanín. Najvyššia miera podobnosti je pri použití hodnoty $k = 8$, kde sa zhoduje dotazovaná tkanina s nájdenou tkaninou z kolekcie tkanín. Ďalšie príklady sú uvedené v prílohe č. 5.




Obr. 26 (R15-r1) Dotazovaná tkanina, (a1) vyhládaná tkanina, graf sim pre uhol 0° .



(R15-r2)




$$k = 8$$




(a1)


Obr. 27 (R15-r2) Dotazovaná tkanina, (a1) vyhľadaná tkanina, graf *sim* pre uhol -7° .



(R15-r3)




$$k = 8$$




(a1)


Obr. 28 (R15-r3) Dotazovaná tkanina, (a1) vyhľadaná tkanina, graf *sim* pre uhol -14° .



(R15-r4)



$$k = 16$$




(a1)


Obr. 29 (R15-r4) Dotazovaná tkanina, (a1) vyhľadaná tkanina, graf *sim* pre uhol -21° .

Na obr. 30 (R17-r1), obr. 31 (R17-r2), obr. 32 (R17-r3) a obr. 33 (R17-r4) sú príklady druhej tkaniny naskenovanej v 4 rôznych smeroch. Tkaniny sa testovali pri rôznej


hodnote k . Výsledky merania ukázali, že najväčšia miera podobnosti u týchto tkanín je pri použití hodnoty $k = 5$, kde sa zhoduje dotazovaná tkanina s nájdenou tkaninou z kolekcie tkanín. U tkaniny na obr. 32 (R17-r3) je ale najväčšia miera podobnosti pri hodnote $k = 4$. Obr. 30 (a1), obr. 31 (a1), obr. 32 (a1) a obr. 33 (a1) zobrazuje nájdené podobné tkaniny. Ďalšie príklady sú uvedené v prílohe č. 5.




Obr. 30 (R17-r1) Dotazovaná tkanina, (a1) vyhládaná tkanina, graf *sim* pre uhol 4° .



Obr. 31 (R17-r2) Dotazovaná tkanina, (a1) vyhládaná tkanina, graf *sim* pre uhol 3° .



Obr. 32 (R17-r3) Dotazovaná tkanina, (a1) vyhľadaná tkanina, graf *sim* pre uhol -1° .



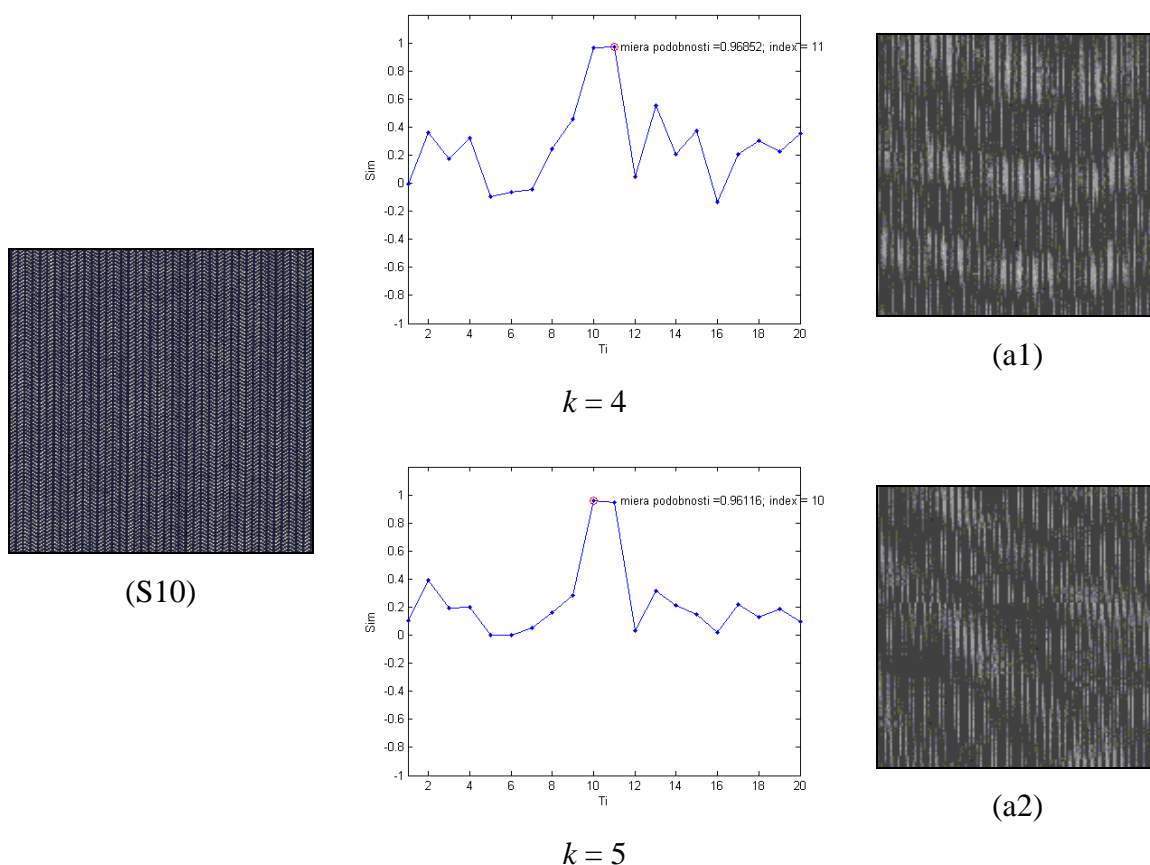
Obr. 33 (R17-r4) Dotazovaná tkanina, (a1) vyhľadaná tkanina, graf *sim* pre uhol -4° .

5.1.2 Náhodne vybrané tkaniny z kolekcie naskenovaných tkanín

Pre toto testovanie sa vybrali 3 tkaniny z kolekcie naskenovaných tkanín, ktoré sa testovali pri rôznej hodnote k . Na základe výsledkov meraní bola zistená najväčšia miera podobnosti a to pri hodnote $k = 3, 5, 8$.

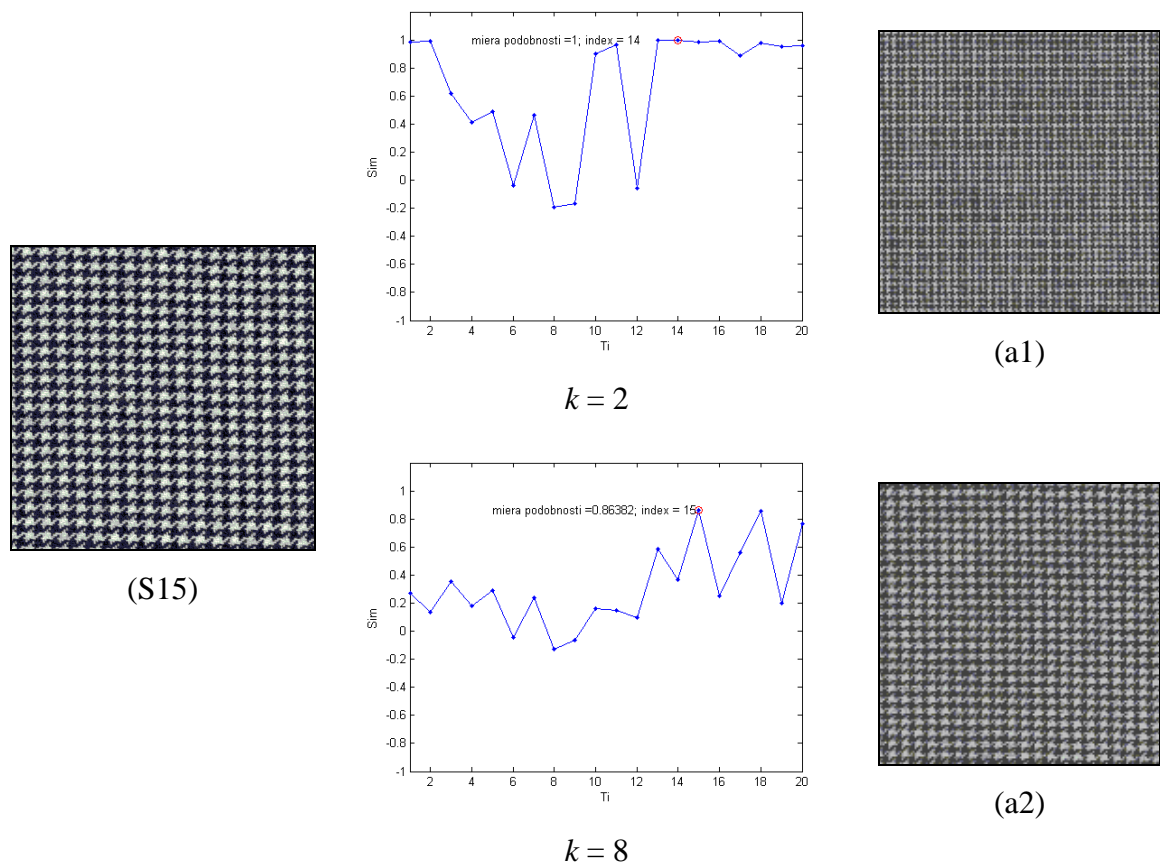
Na obr. 34 je príklad prvej tkaniny náhodne vybranej z kolekcie tkanín. Dotazovaná tkanina je natáčaná v uhle od -25° do 25° s krokom 1° . Veľkosť výrezu bola nastavená na 100×100 pixelov pri rôznej hodnote k . Na obr. 34 (S10) je znázornená naskenovaná tkanina v úrovni šedi, ktorá je porovnávaná s kolekciou tkanín. Obr. 34 (a1) – (a2) znázorňuje rekonštrukciu obrázku vyhľadanej tkaniny. Na grafoch možno vidieť jednotlivé miery podobnosti výkonových spektier dotazovanej tkaniny s kolekciou tkanín pri rôznej hodnote k . Tieto grafy boli zostrojené pri konkrétnom uhle pootočenia, kde bola miera

podobnosti najväčšia. Sim označuje mieru podobnosti a T_i značí jednotlivé tkaniny z kolekcie tkanín. Červený krúžok označuje maximálnu hodnotu nájdenia miery podobnosti. Najvyššia miera podobnosti je pri použití hodnoty $k = 5$, kde sa zhoduje dotazovaná tkanina s nájdenou tkaninou z kolekcie tkanín. Pri hodnote $k = 4$ bola vyhl'adaná podobná tkanina – S11. Ďalšie príklady sú uvedené v prílohe č. 5.




Obr. 34 (S10) Dotazovaná tkanina, (a1) – (a2) vyhl'adaná tkanina, grafy sim pre uhol 0° .

Na obr. 35 je príklad druhej tkaniny náhodne vybranej z kolekcie tkanín. Najvyššia miera podobnosti je pri použití hodnoty $k = 8$, kde sa zhoduje dotazovaná tkanina s nájdenou tkaninou z kolekcie tkanín. Pri hodnote $k = 2$ bola vyhl'adaná podobná tkanina – S14. Ďalšie príklady sú uvedené v prílohe č. 5.



Obr. 35 (S15) Dotazovaná tkanina, (a1) – (a2) vyhládaná tkanina, grafy *sim* pre uhol 2° .

Na obr. 36 je príklad tretej tkaniny náhodne vybranej z kolekcie tkanín. Najvyššia miera podobnosti je pri použití hodnoty $k = 3$, kde sa zhoduje dotazovaná tkanina s nájdenou tkaninou z kolekcie tkanín. Ďalšie príklady sú uvedené v prílohe č. 5.



Obr. 36 (S7) Dotazovaná tkanina, (a1) vyhládaná tkanina, graf *sim* pre uhol -12° .

5.1.3 Vyhľadávanie v databáze textúr textílií a textilných vzorov

Testovanie sa prevádzalo v databáze textúr textílií a textilných vzorov, kde sa náhodne vybrali 4 plošné textílie – 2 tkaniny a 2 netkané textílie.


Veľkosť výrezu bola nastavená na 100×100 pixelov pri rôznej hodnote k . Na základe testov sa textílie testovali pri hodnote $k = 3, 4, 5, 8, 16, 20, 50$.

Na obr. 37 (D5) je príklad tkaniny náhodne vybranej z databázy textúr. Obr. 37 (a1) zobrazuje vyhladanú podobnú tkaninu. Pri hodnote $k = 5, 8, 16, 20, 50$ boli nájdené podobné textílie. Tá istá tkanina bola vyhladaná pri $k = 50$. Obr. 37 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D6, D85, D75, D93, D330, D161. Na grafoch možno vidieť jednotlivé miery podobnosti výkonových spektier dotazovanej textílie s textíliami z databázy textúr pri rôznej hodnote k . Tieto grafy boli zostrojené pri konkrétnom uhle pootočenia, kde bola miera podobnosti najväčšia. *Sim* označuje mieru podobnosti a T_i značí jednotlivé textílie z databázy. Červený krúžok označuje maximálnu hodnotu nájdenia miery podobnosti. Ďalšie príklady sú uvedené v prílohe č.5.


Na obr. 38 (D38) je príklad tkaniny náhodne vybranej z databázy textúr. Pri hodnote $k = 50$ bola nájdená podobná tkanina. Tá istá tkanina bola vyhladaná pri $k = 8, 16, 20, 50$. Obr. 38 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D67, D249, D216, D145, D155, D294. Ďalšie príklady sú uvedené v prílohe č.5.

Na obr. 39 (D294) je príklad netkanej textílie náhodne vybranej z databázy textúr. Pri hodnote $k = 16$ bola nájdená podobná netkaná textília. Obr. 39 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D339, D217, D235, D306, D250, D341. Ďalšie príklady sú uvedené v prílohe č.5.


Na obr. 40 (D318) je príklad netkanej textílie náhodne vybranej z databázy textúr. Pri hodnote $k = 4$ boli nájdené podobné netkané textílie. Obr. 40 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D298, D295, D173, D29, D49, D329. Ďalšie príklady sú uvedené v prílohe č.5.




(D5)




$k = 5$




(a1)




(v1)




(v2)




(v3)



(v4)




(v5)





(v6)

Obr. 37 (D5) Dotazovaná tkanina, (a1) vyhládaná textília, (v1) – (v6) podobná textília, graf *sim* pre uhol 1° .




(D38)




(a1)


$k = 8$




(v1)




(v2)




(v3)



(v4)




(v5)





(v6)

Obr. 38 (D38) Dotazovaná tkanina, (a1) vyhládaná textília, (v1) – (v6) podobná textília, graf *sim* pre uhol 0° .




(D294)




(a1)


$k = 16$




(v1)




(v2)




(v3)



(v4)




(v5)




(v6)


Obr. 39 (D294) Dotazovaná netkaná textília, (a1) vyhľadaná textília, (v1) – (v6) podobná textília, graf *sim* pre uhol 25°.




(D318)




$k = 4$




(a1)




(v1)




(v2)



(v3)



(v4)



(v5)



(v6)

Obr. 40 (D318) Dotazovaná netkaná textília, (a1) vyhl'adaná textília, (v1) – (6) podobná textília, graf *sim* pre uhol -24° .

6 Invariantné (nemenné) momenty

2D moment rádu $(p+q)$ digitálneho obrazu $f(x, y)$ je definovaný ako

$$m_{pq} = \sum_x \sum_y x^p y^q f(x, y), \quad (15)$$

pre $p, q = 0, 1, 2, \dots$, kde súčty sú cez hodnoty priestorových súradníc x a y daného obrazu [5]. Odpovedajúci centrálny moment je definovaný ako

$$u_{pq} = \sum_x \sum_y (x - \bar{x})^p (y - \bar{y})^q f(x, y), \quad (16)$$

kde

$$\bar{x} = \frac{m_{10}}{m_{00}} \quad a \quad \bar{y} = \frac{m_{01}}{m_{00}}. \quad (17)$$

Normalizovaný centrálny moment rádu $(p+q)$ je definovaný ako:

$$\eta_{pq} = \frac{\mu_{pq}}{\mu_{00}^\gamma}, \quad (18)$$

pre $p, q = 0, 1, 2, \dots$, kde

$$\gamma = \frac{p+q}{2} + 1, \quad (19)$$

pre $p+q = 2, 3, \dots$.

Súbor siedmych 2D invariantných momentov, ktoré sú invariantné voči posunu, zmene veľkosti, zrkadlovému otočeniu a rotácií, môžu byť odvodené z týchto rovníc:


$$\begin{aligned}
\phi_1 &= \eta_{20} + \eta_{02}, \\
\phi_2 &= (\eta_{20} - \eta_{02})^2 + 4\eta_{11}^2, \\
\phi_3 &= (\eta_{30} - 3\eta_{12})^2 + (3\eta_{21} - \eta_{03})^2, \\
\phi_4 &= (\eta_{30} + \eta_{12})^2 + (\eta_{21} + \eta_{03})^2, \\
\phi_5 &= (\eta_{30} - 3\eta_{12})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\
&\quad + (3\eta_{21} - \eta_{03})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] \\
\phi_6 &= (\eta_{20} - \eta_{02})[(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2] + 4\eta_{11}(\eta_{30} + \eta_{12})(\eta_{21} + \eta_{03}), \\
\phi_7 &= (3\eta_{21} - \eta_{03})(\eta_{30} + \eta_{12})[(\eta_{30} + \eta_{12})^2 - 3(\eta_{21} + \eta_{03})^2] \\
&\quad + (3\eta_{12} - \eta_{30})(\eta_{21} + \eta_{03})[3(\eta_{30} + \eta_{12})^2 - (\eta_{21} + \eta_{03})^2]
\end{aligned} \tag{20}$$

M-funkcia pre výpočet invariantných momentov *invmoments.m* [5], vracia 7 invariantných momentov. Syntax je nasledujúca:


$$phi = invmoments(f) \tag{21}$$

kde *f* je definovaný ako vstupný obraz a *phi* ako sedemprvkový riadkový vektor obsahujúci invariantné momenty.


Na obr. 41 je príklad tkaniny a jej úpravy. Obr. 41 (a) znázorňuje originálny obraz tkaniny, (b) je obraz o polovičnej veľkosti, (c) znázorňuje zrkadlovo prevrátený obraz, (d) je obraz otočený o 2° a (e) je obraz otočený o 45°. Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom *inv_obrázky.m*.




(a)




(b)



(c)



(d)



(e)

Obr. 41 (a) Originálny obraz, (b) obraz o polovičnej veľkosti, (c) zrkadlovo prevrátený obraz, (d) otočený obraz o 2° , (e) otočený obraz o 45° .

V tabuľke 2 je zhrnutých sedem invariantných momentov originálneho obrazu, obrazu o polovičnej veľkosti, zrkadlovo prevráteného obrazu, obrazu otočeného o 2° a 45° .

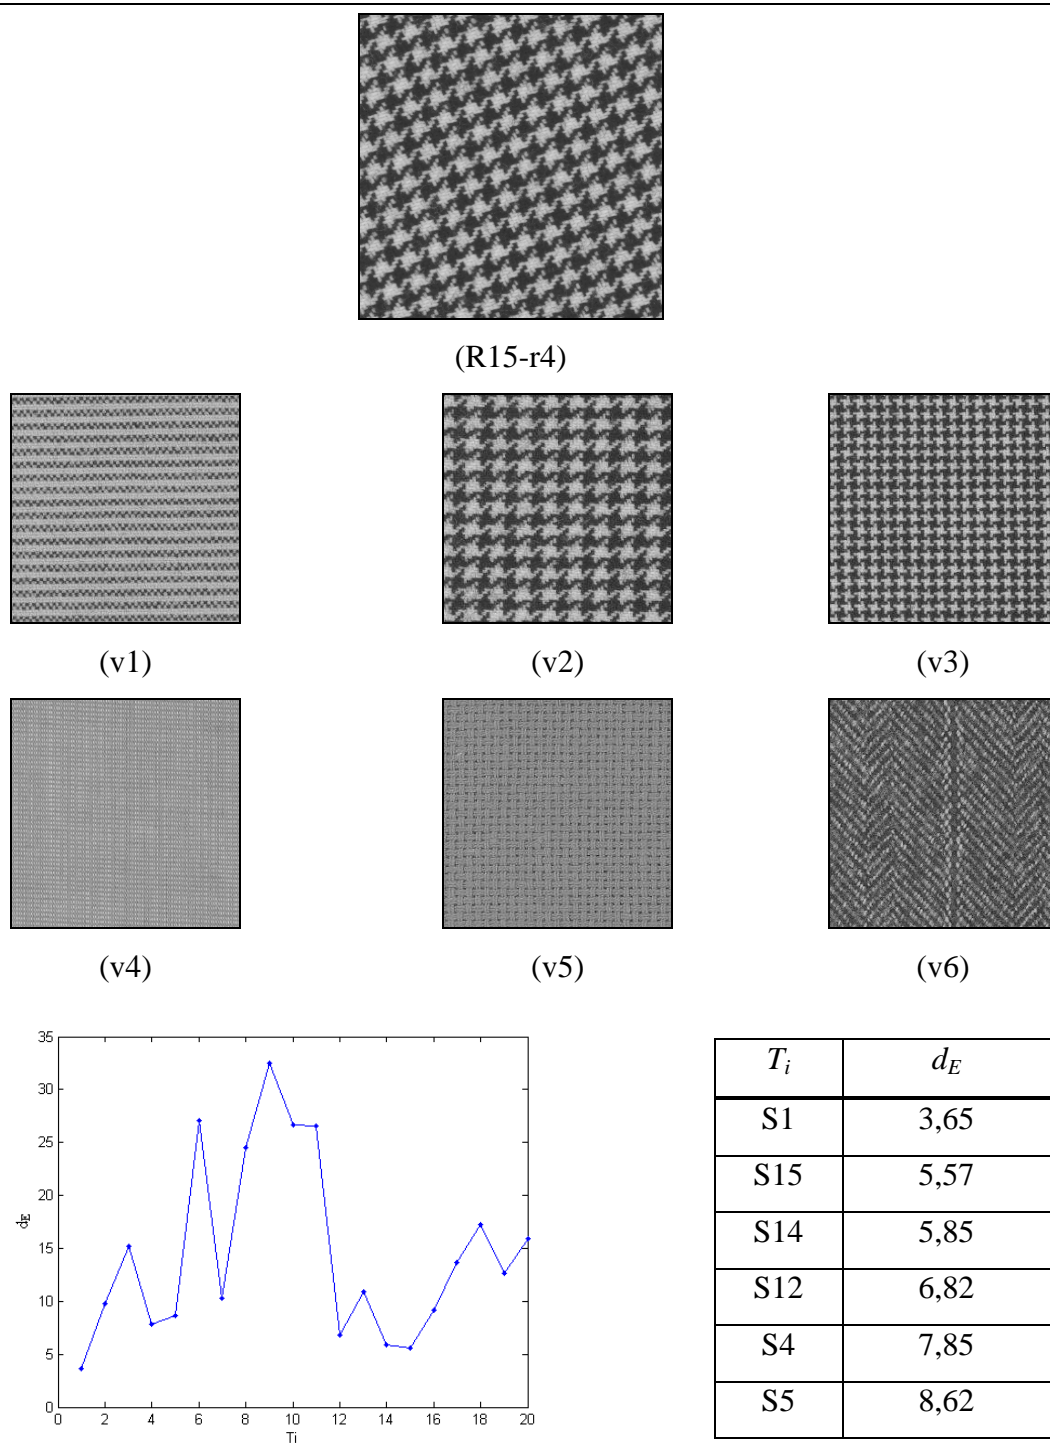
Tab. 2 Sedem invariantných momentov pre obrázky na obr. 41 (a) – (e).

Invariantný moment	Originálny obraz	Polovičná veľkosť	Zrkadlovo prevrátený	Otočený o 2°	Otočený o 45°
ϕ_1	6,8408	6,8405	6,8408	6,8408	6,8407
ϕ_2	16,5513	16,5421	16,5513	16,5513	16,5513
ϕ_3	30,1774	30,4068	30,1774	30,1776	30,1706
ϕ_4	28,9250	28,9279	28,9250	28,9252	28,9259
ϕ_5	58,8062	58,7913	58,8062	58,8064	58,8097
ϕ_6	37,3334	37,3316	37,3334	37,3336	37,3343
ϕ_7	58,9486	59,3981	59,0322	58,9494	58,9379

6.1 Testovacia sada 5

V tejto testovacej sade sa uskutočňovalo testovanie metódy pomocou invariantných momentov. Testovanie sa prevádzalo na tkanine natočenej v rôznom smere. Porovnávajú sa vzdialenosti invariantných momentov – vektory. Týchto vektorov je 7. Čím menšia vzdialenosť (Euklidova), tým sú si textílie podobné. Zdrojový kód pre túto metódu je uvedený v prílohe č. 1 pod názvom `inv_01.m`.

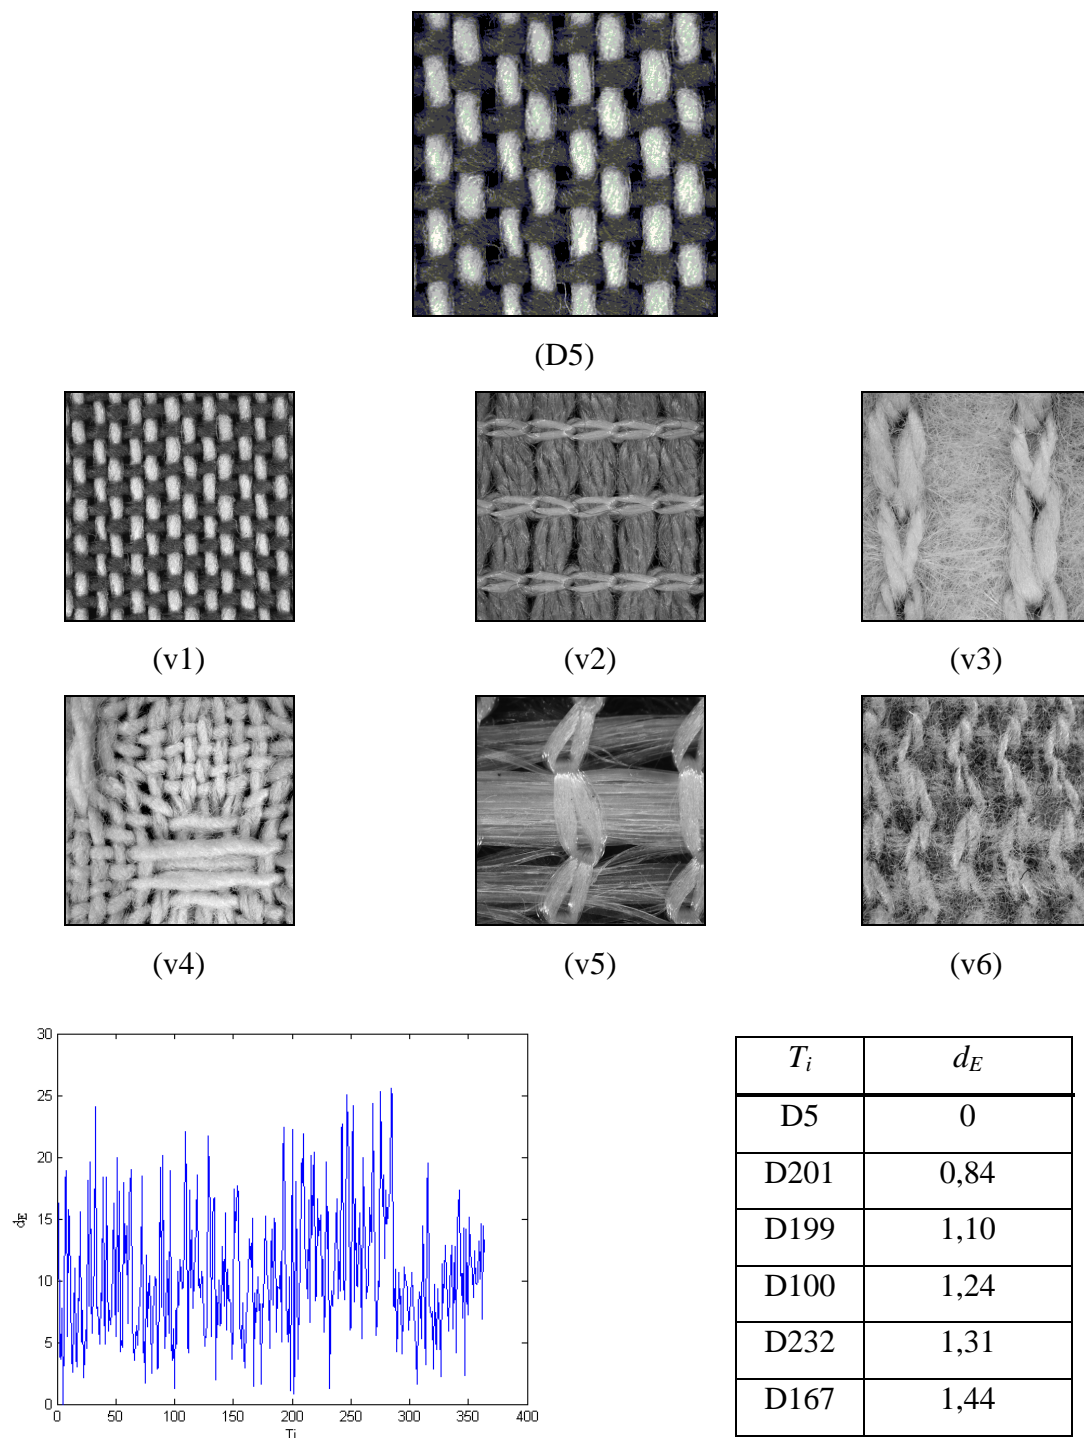
Na obr. 42 (R15-r4) je príklad tkaniny natočenej v rôznom smere. Obr. 42 (v1) – (v6) znázorňuje prvých 6 tkanín nájdených v kolekcii s najväčšou mierou podobnosti – v kolekcii tkanín sú to tkaniny S1, S15, S14, S12, S4, S5. Graf vykresľuje jednotlivé vzdialenosti dotazovanej tkaniny s tkaninami v kolekcii. V grafe sa Euklidova vzdialenosť označuje skratkou d_E a T_i značí jednotlivé tkaniny z kolekcie tkanín.



Obr. 42 (R15-r4) Dotazovaná tkanina, (v1) – (v6) vyhl'adaná textília, graf *sim*.

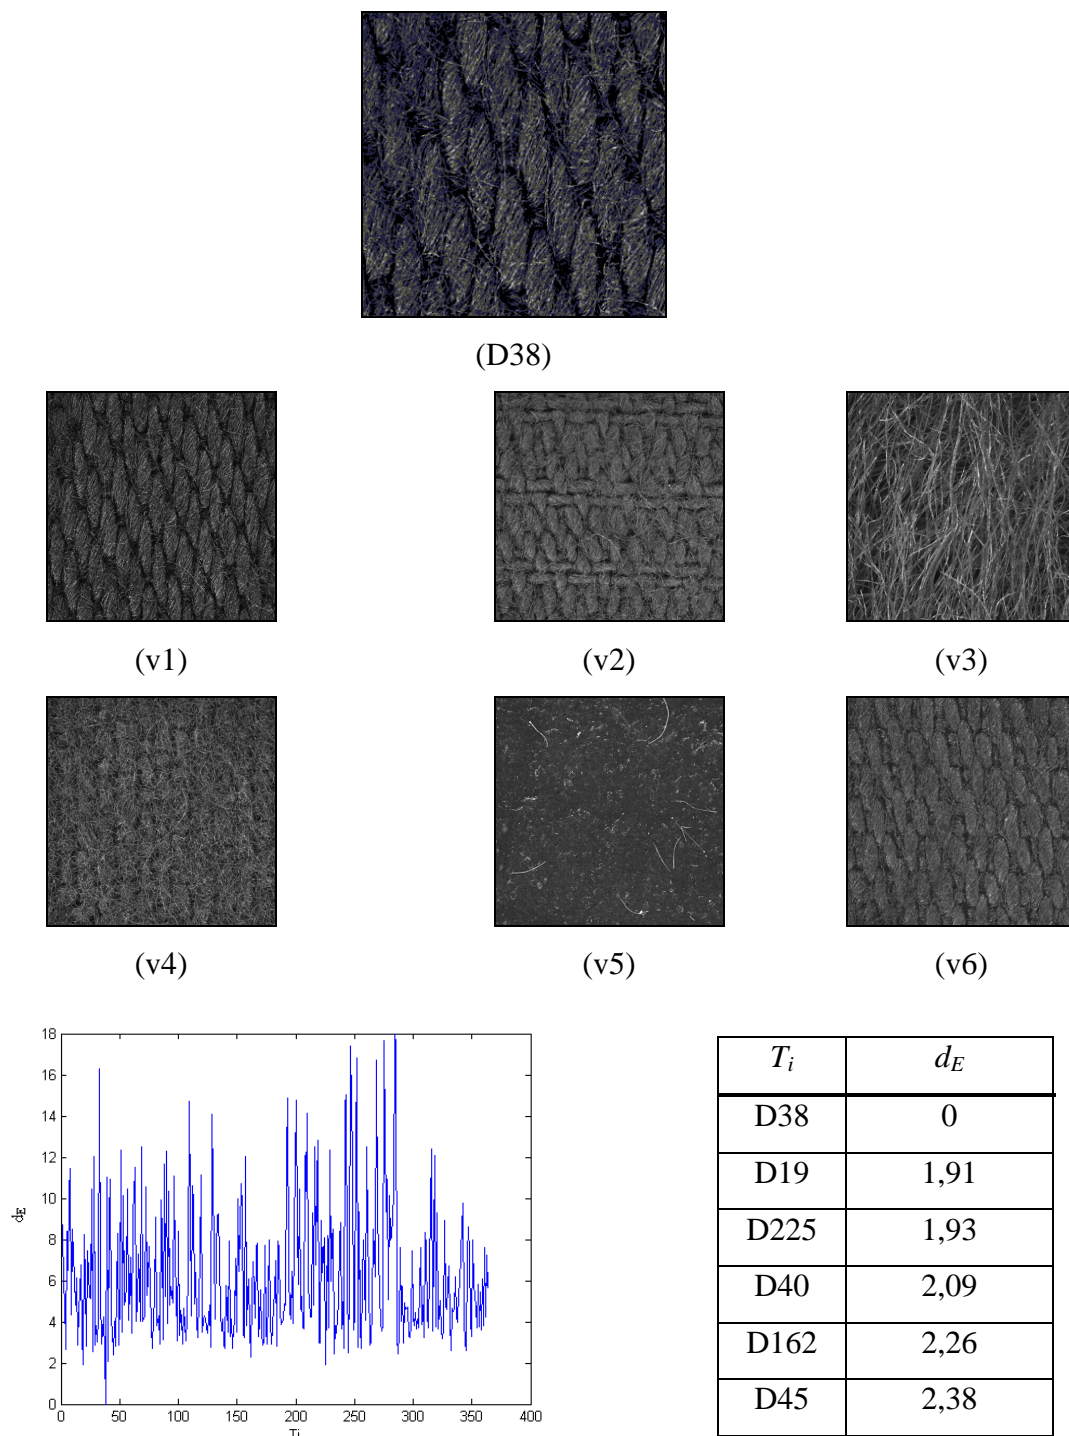
Testovanie sa prevádzalo aj na databáze textúr textílií a textilných vzorov. Náhodne sa vybrali 4 plošné textílie – 2 tkaniny a 2 netkané textílie.

Na obr. 43 (D5) je príklad tkaniny náhodne vybranej z databázy textúr. Obr. 43 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D5, D201, D199, D100, D232, D167.



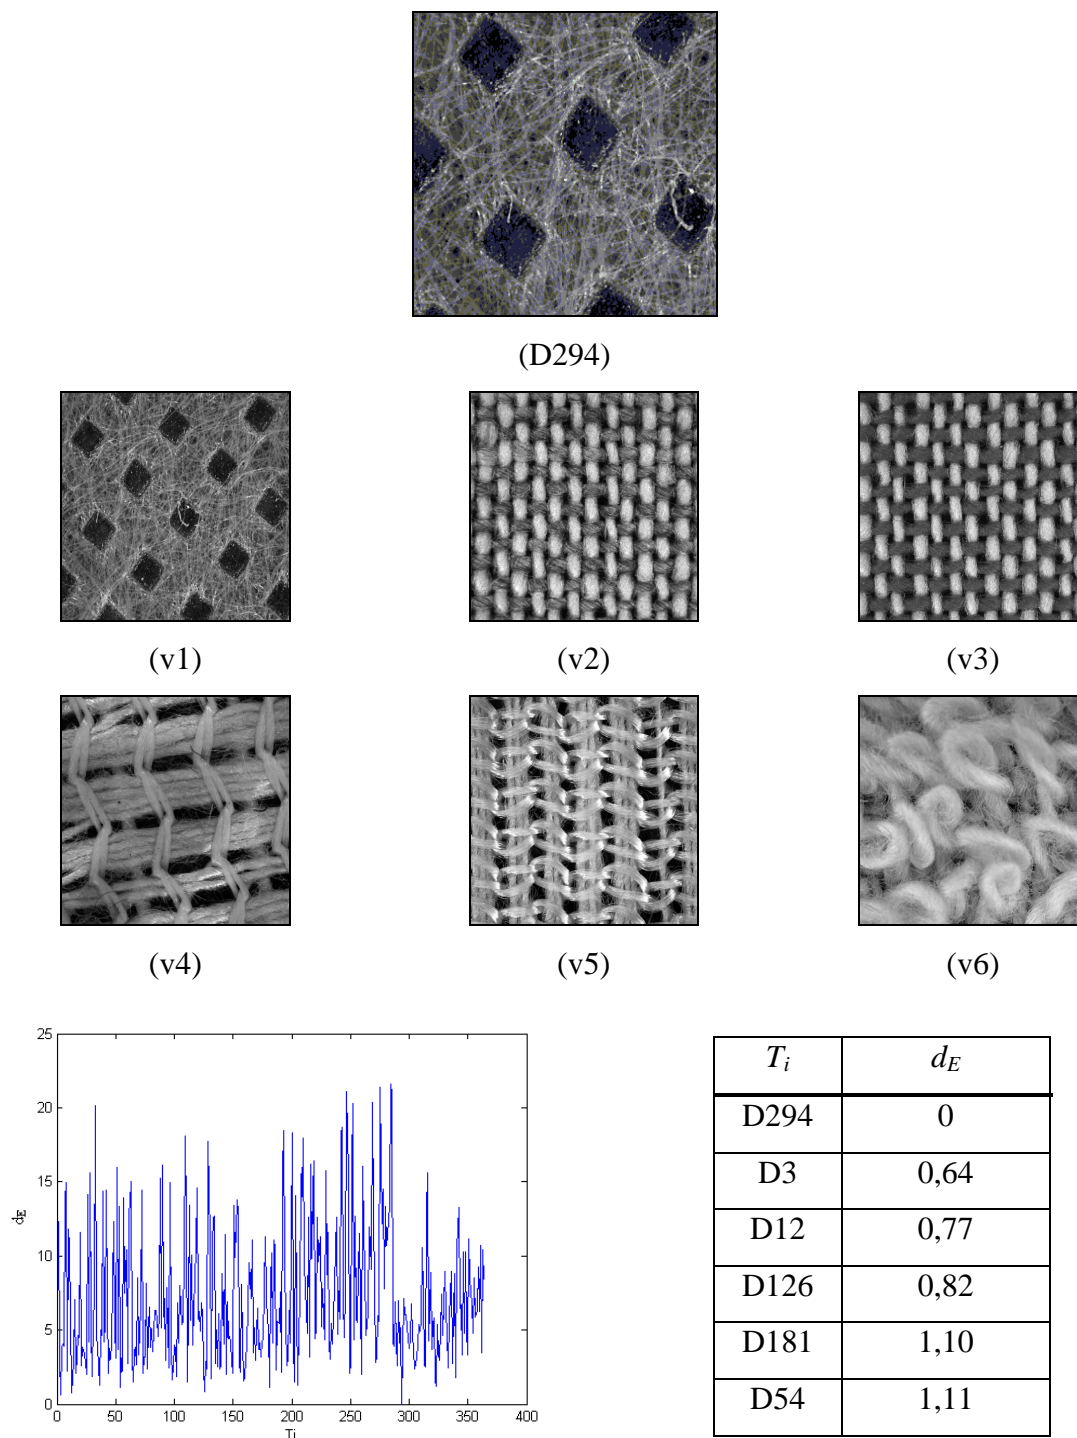
Obr. 43 (D5) Dotazovaná tkanina, (v1) – (v6) vyhládaná textília, graf *sim*.

Na obr. 44 (D38) je príklad tkaniny náhodne vybranej z databázy textúr. Obr. 44 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D38, D19, D225, D40, D162, D45.



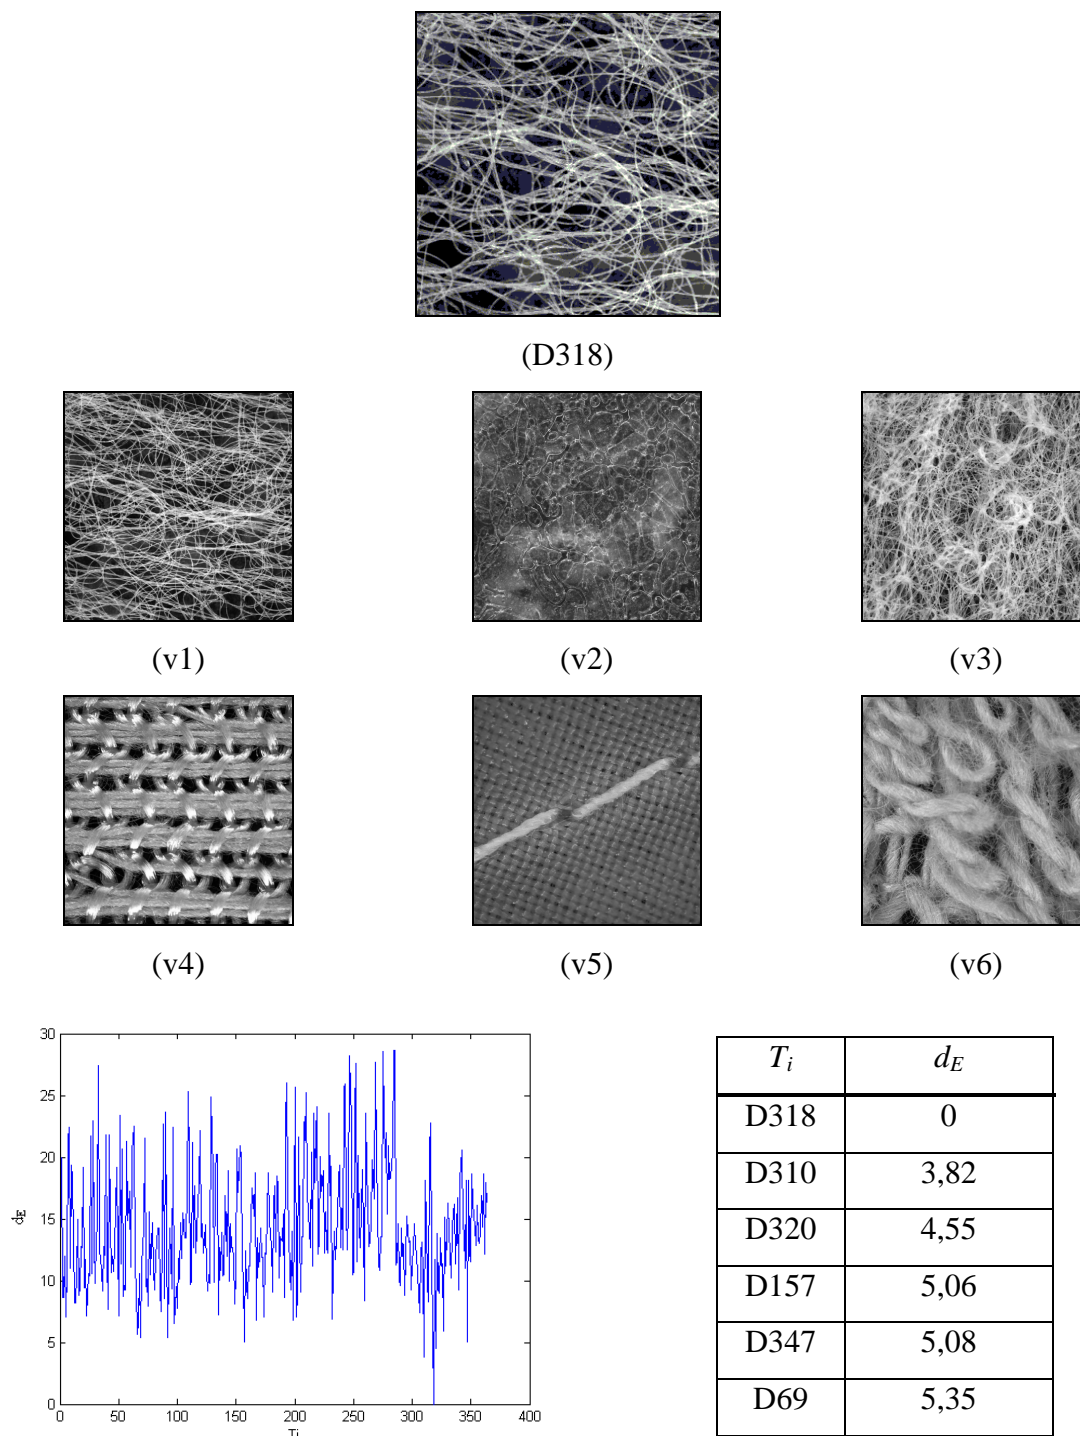
Obr. 44 (D38) Dotazovaná tkanina, (v1) – (v6) vyhládaná textília, graf *sim*.

Na obr. 45 (D294) je príklad netkanej textílie náhodne vybranej z databázy textúr. Obr. 45 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D294, D3, D12, D126, D181, D54.



Obr. 45 (D294) Dotazovaná netkaná textília, (v1) – (v6) vyhládaná textília, graf *sim*.

Na obr. 46 (D318) je príklad netkanej textílie náhodne vybranej z databázy textúr. Obr. 46 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D318, D310, D320, D157, D347, D69.



Obr. 46 (D318) Dotazovaná netkaná textília, (v1) – (v6) vyhládaná textílie, graf *sim*.

7 Porovnávanie koreláciou

Obraz je daný funkciou $f(x,y)$. Úlohou metódy porovnávanie koreláciou [5] je nájsť všetky miesta v obraze, ktoré zodpovedajú podobrázku (filter, maska, šablóna) $w(x,y)$. Šablóna $w(x,y)$ je väčšinou menšieho rozmeru ako $f(x,y)$. Jeden prístup pre hľadanie podobnosti je použiť šablónu $w(x,y)$ ako priestorový filter a spočítať sumu produktov pre každú pozíciu w v obraze f . Potom najlepšia zhoda $w(x,y)$ v obraze $f(x,y)$ je miesto maximálnej hodnoty vo výslednom korelovanom obraze. Filtrácia v priestorovej oblasti je hardwarovo a časovo náročná.

Alternatívnym prístupom je implementovať koreláciu vo frekvenčnej oblasti, s využitím konvolučnej vety. Nech " \circ " označuje koreláciu a " $*$ " komplexnú konjunkciu (zmena znamienka komplexnej zložky) potom:

$$f(x,y) \circ w(x,y) \Leftrightarrow F(u,v) * H(u,v). \quad (22)$$


Inými slovami, korelácia v priestorovej oblasti môže byť získaná ako inverzná Fourierova transformácia produktov transformácie jednej funkcie krát konjungovaná transformácia druhej. Obrátene, z toho vyplýva, že

$$f(x,y) * w(x,y) \Leftrightarrow F(u,v) \circ H(u,v). \quad (23)$$


Testovanie metódy porovnávania pomocou korelácie sa prevádzalo na databáze textúr textílií a textilných vzorov. Z tejto databázy sa vybrali 2 textílie – tkanina a netkaná textília. Zdrojové kódy pre túto metódu sú uvedené v prílohe č. 1 pod názvom `cormatch.m`, `dftcorr.m`, `cormatch_01.m`.

Na obr. 47 (D5) je príklad tkaniny náhodne vybranej z databázy textúr. Veľkosť výrezu tkaniny bol nastavený na 500×500 pixelov. Červený štvorec na tkanine predstavuje podobrázok obr. 47 (a), ktorého veľkosť je 75×75 pixelov so súradnicami [136,321]. Tento podobrázok predstavuje masku, filter, jadro. Postupne prechádza celou tkaninou a následne sa vypočítala korelácia medzi tkaninou a podobrázkom. Koreláciu vo forme šedotónového obrazu medzi tkaninou a podobrázkom zobrazuje obr. 47 (b). Sú vidieť opakujúce sa svetlé body - mriežka, kde dochádza k zhode medzi tkaninou a podobrázkom. Obr. 47 (c)


predstavuje miesto najlepšej zhody, ktoré je označené bielou farbou. Súradnice [136,321] bieleho bodu odpovedajú súradniciam podobrázka.




(D5)



(a)




(b)




(c)

Obr. 47 (D5) Tkanina, (a) podobrázok, (b) korelácia tkaniny a podobrázka, (c) miesto najlepšej zhody.


Druhá vybraná textília z databázy textúr bola netkaná textília obr. 48 (D339). Veľkosť výrezu netkanej textílie bol nastavený na 500×500 pixelov. Výrez podobrázka obr. 48 (a) je veľkosti 100×100 pixelov so súradnicami [141,290]. Koreláciu vo forme šedotónového okna medzi tkaninou a podobrázkom zobrazuje obr. 48 (b). Na obr. 48 (c) je miesto najlepšej zhody, ktoré je označené bielou farbou. Súradnice [141,290] bieleho bodu odpovedajú súradniciam podobrázka.




(D339)



(a)



(b)



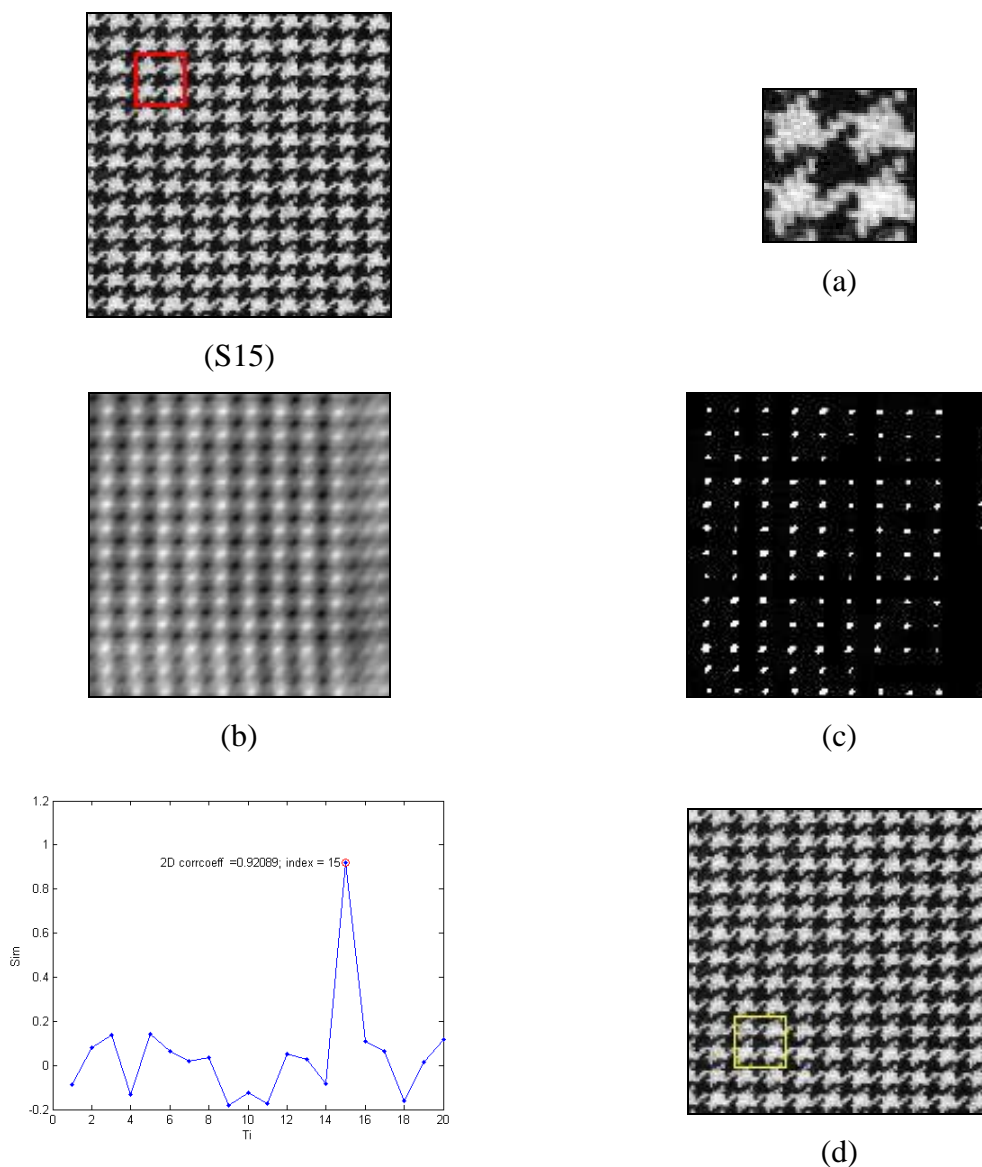
(c)

Obr. 48 (D339) Netkaná textília, (a) podobrázok, (b) korelácia netkanej textílie a podobrázka, (c) miesto najlepšej zhody.

7.1 Testovacia sada 6

Porovnávanie pomocou korelácie sa testovalo na tkanina náhodne vybranej z kolekcie naskenovaných tkanín. Veľkosť výrezu tkaniny bol nastavený na 300×300 pixelov. Na obr. 49 (S15) je zobrazená tkanina a červený štvorec zobrazený na tkanine predstavuje výrez podobrázka na obr. 49 (a). Tento podobrázok prechádza každou tkaninou, pixel za pixelom, z kolekcie naskenovaných tkanín. Pre každú tkaninu sa vypočíta maximálna korelácia, ktorá sa vynesie do grafu. *Sim* na grafe označuje mieru podobnosti a T_i označuje jednotlivé tkaniny z kolekcie naskenovaných tkanín. Červený krúžok v grafe označuje maximálnu nájdenú mieru podobnosti z jednotlivých tkanín. Veľkosť podobrázka bola nastavená na 50×50 pixelov so súradnicami [41,50]. Koreláciu vo forme šedotónového okna medzi tkaninou a podobrázkom zobrazuje obr. 49 (b). Na obrázku sú vidieť opakujúce sa svetlé body, ktoré zobrazujú zhodu. Obr. 49 (c) je prevedený do binárneho obrazu a predstavuje miesta najlepšej zhody, ktoré sú označené bielou farbou. Obr. 49 (d) znázorňuje vyhl'adanú, podobnú tkaninu. Žltý štvorec na tkanine

označuje miesto nájdenia rovnakého výrezu ako na obr. 49 (S15). Napriek tomu, že bola vyhl'adaná tá istá tkanina, na tkanine neodpovedá pozícia žltého štvorca s pozíciou červeného štvorca na obr. 49 (S15). Túto metódu možno brať za úspešnú i keď neodpovedajú výrezy na tkaninách.

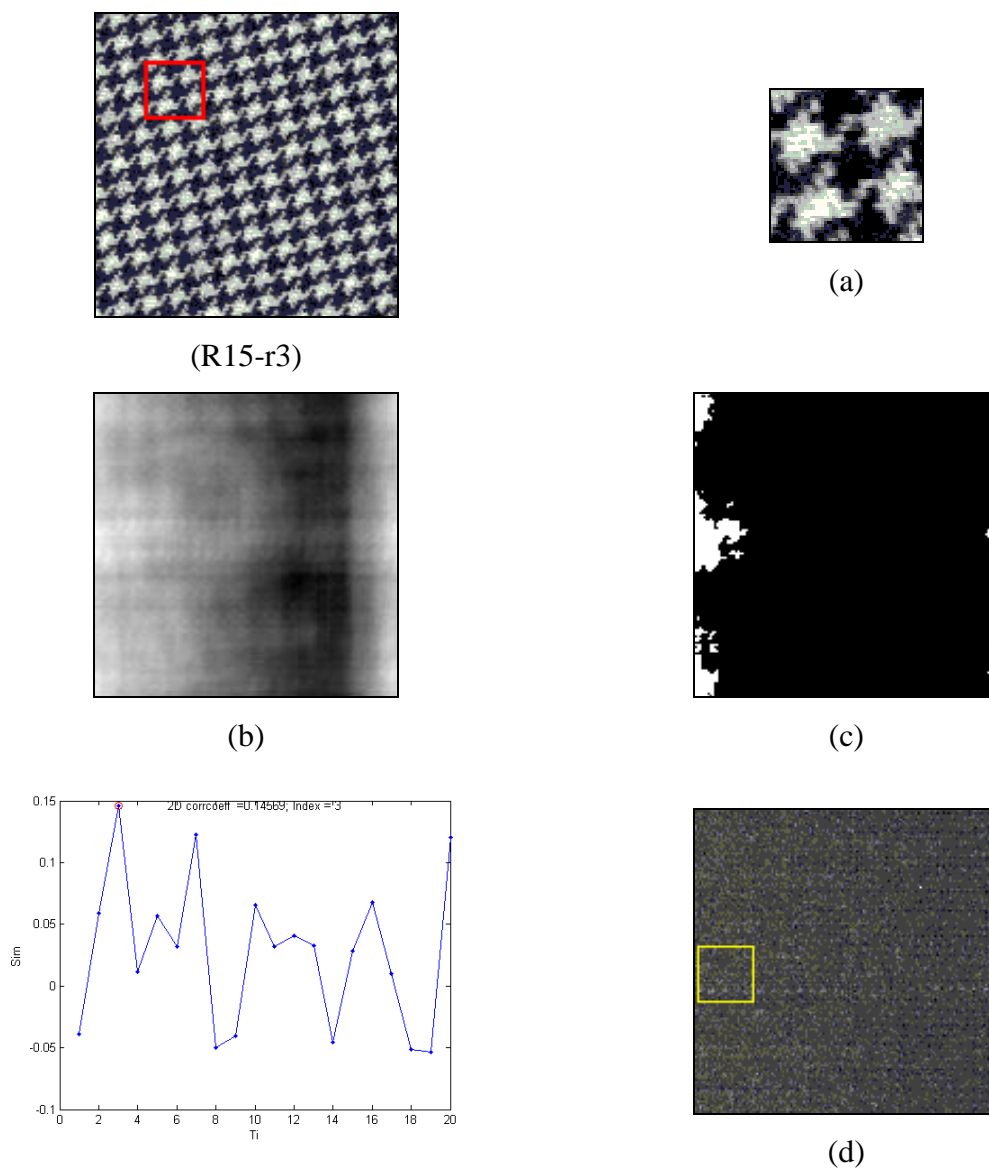


Obr. 49 (S15) Tkanina, (a) podobrázok, (b) korelácia tkaniny a podobrázka, (c) miesta najlepšej zhody, (d) vyhl'adaná tkanina, graf *sim*.

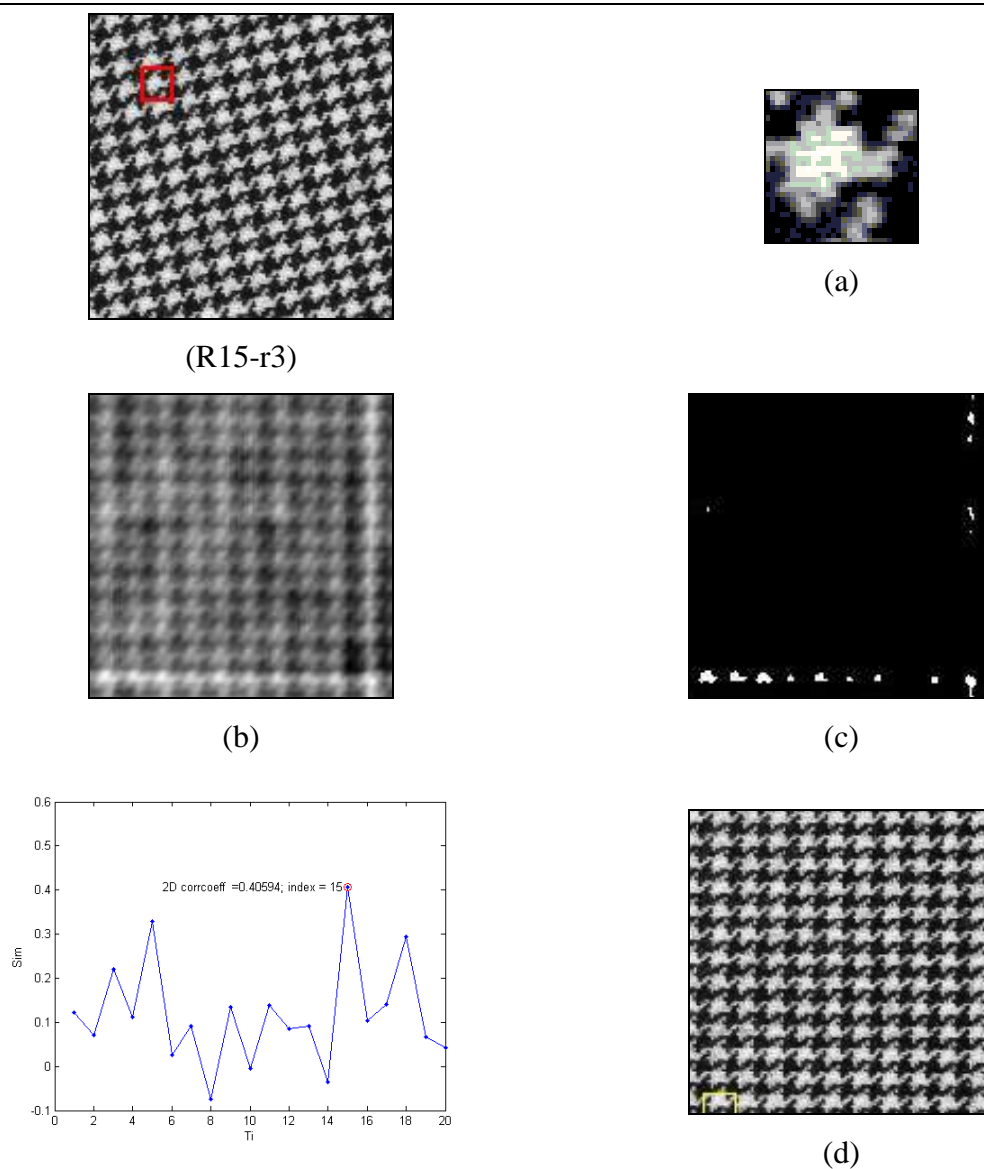
Pri testovaní metódy pomocou porovnávania koreláciou na naskenovanej tkanine potočenej v určitom smere sa ukázalo, že aplikácia metódy nie je vhodná. Metóda je citlivá na rotáciu obrazu. Veľkosť výrezu tkaniny bol nastavený na 300×300 pixelov. Na obr. 50

(R15-r3) je zobrazená tkanina s veľkosťou výrezu podobrázka 55×55 pixelov obr. 50 (a). Obr. 51 (R15-r3) zobrazuje tu istú tkaninu s výrezom podobrázka 30×30 pixelov.

Metóda je vhodná pri veľkosti poobrázka 30×30 pixelov, pri väčšej veľkosti poobrázka 55×55 pixelov vyhládaná tkanina neodpovedá štruktúrou dotazovanej tkaniny.

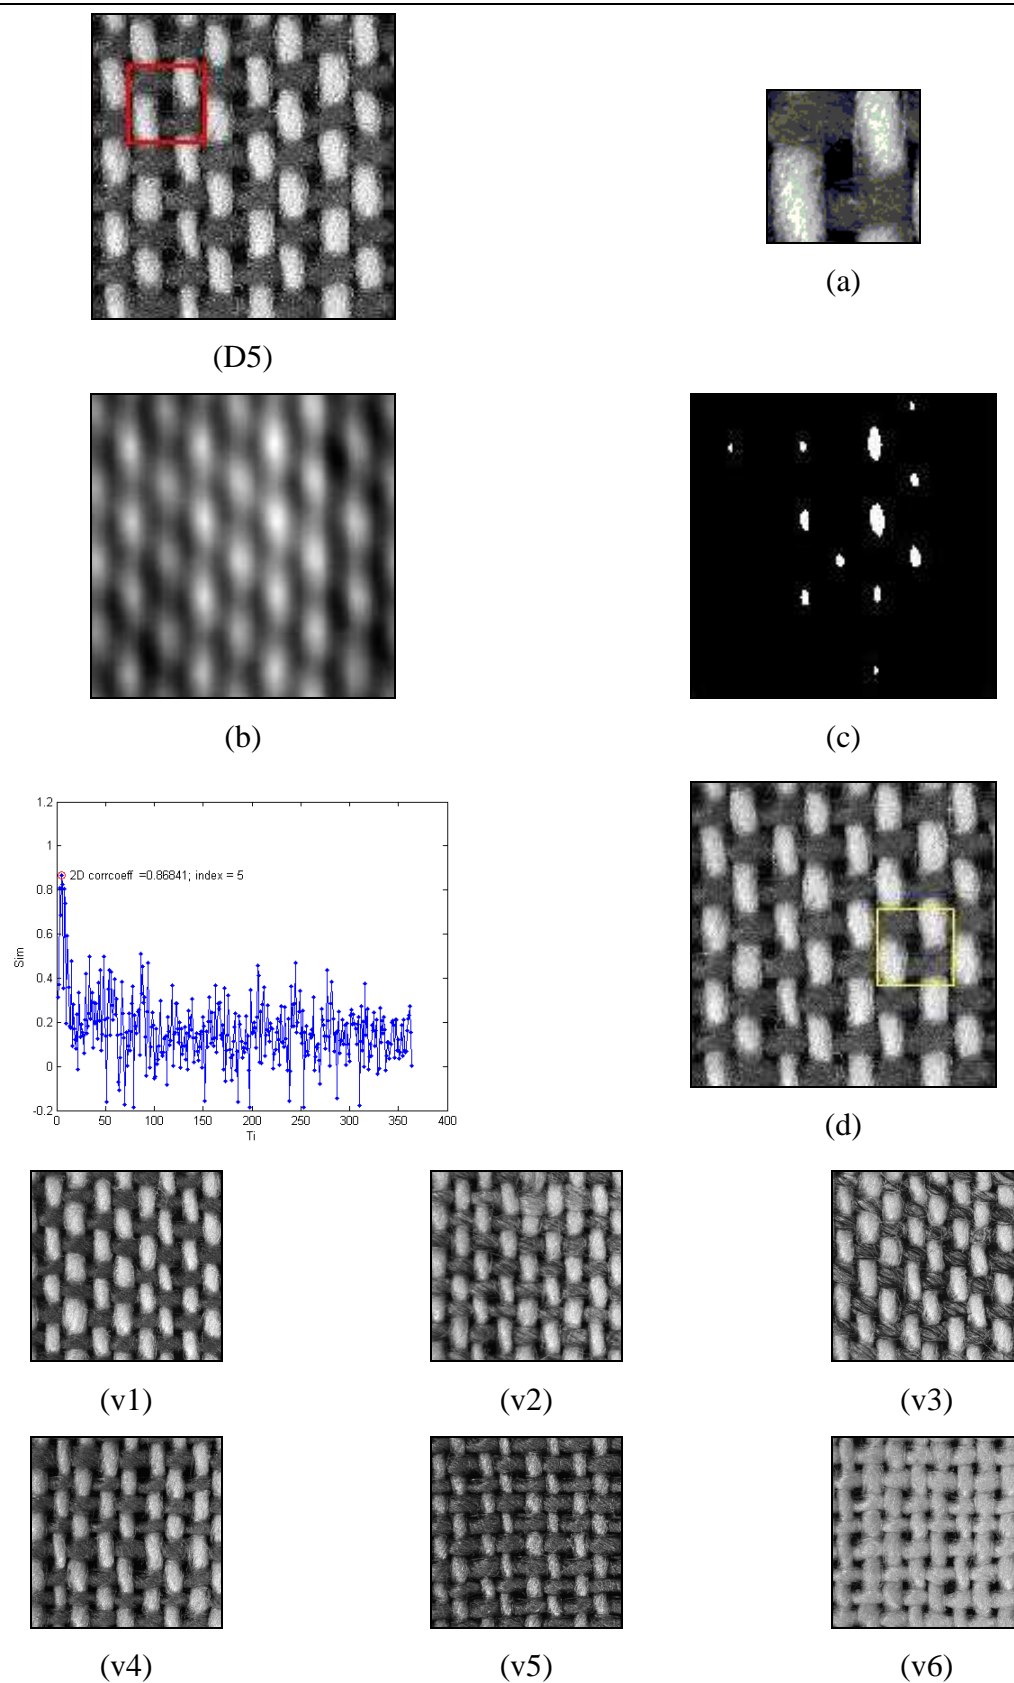


Obr. 50 (R15-r3) Tkanina, (a) podobrázok, (b) korelácia tkaniny a podobrázka, (c) miesto najlepšej zhody, (d) vyhládaná tkanina, graf *sim*.

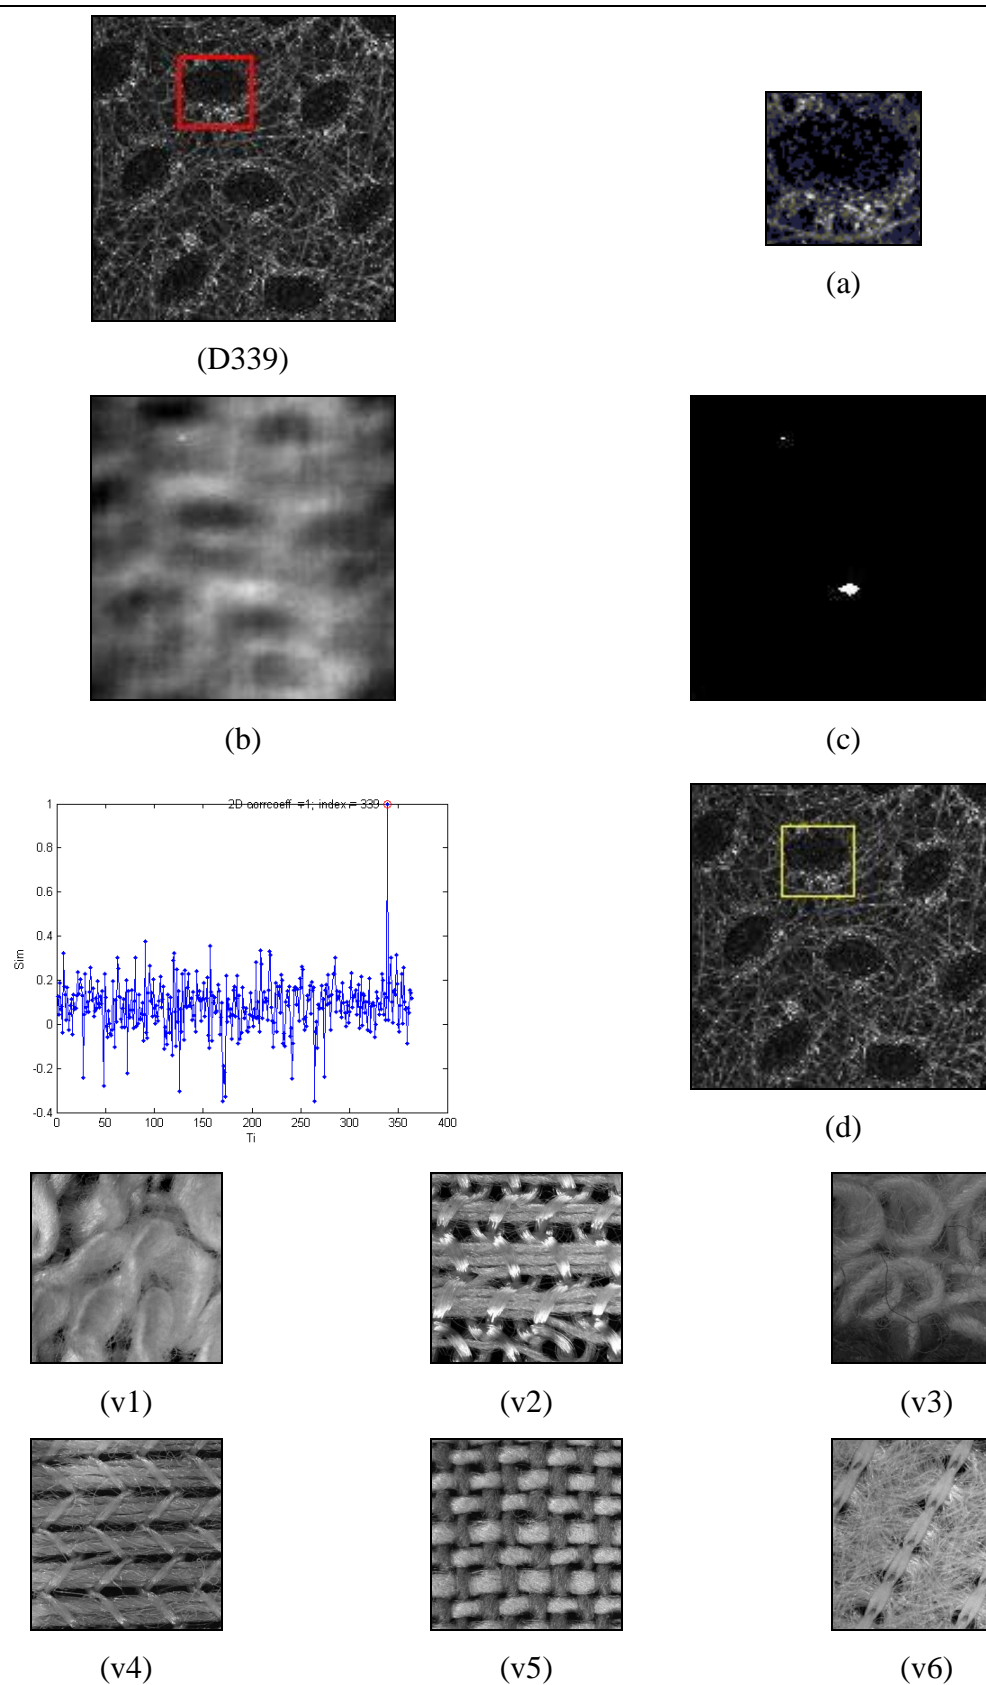


Obr. 51 (R15-r3) Tkanina, (a) podobrázok, (b) korelácia tkaniny a podobrázka, (c) miesto najlepšej zhody, (d) vyhládaná tkanina, graf *sim*.

Testovanie metódy porovnávanie koreláciou sa prevádzalo na databáze textúr. Boli vybrané náhodne dve textílie – tkanina a netkaná textília. Veľkosť výrezu textílie bol nastavený na 300×300 pixelov. Na obr. 52 (D5) je zobrazená tkanina z databázy textúr. Veľkosť podobrázke obr. 52 (a) bola nastavená na 75×75 pixelov. Obr. 52 (v1) – (v6) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D6, D3, D8, D9, D4, D11.



Obr. 52 (D5) Tkanina, (a) podobrázok, (b) korelácia tkaniny a podobrázka, (c) miesto najlepšej zhody, (d) vyhládaná tkanina, (v1) – (v6) podobné tkaniny, graf *sim*.



Obr. 53 (D339) Tkanina, (a) podobrázok, (b) korelácia tkaniny a podobrázka, (c) miesto najlepšej zhody, (d) vyhládaná tkanina, (v1) – (v6) podobná tkanina, graf *sim*.

Na obr. 53 (D338) je zobrazená netkaná textília z databázy textúr. Veľkosť podobrázke bola nastavená na 70×70 pixelov. Obr. 53 (v1) – (v8) znázorňuje prvých 6 textílií nájdených v databáze s najväčšou mierou podobnosti – v databáze textúr sú to textílie D91, D157, D209, D218, D7, D120, D92, D66. Z výsledkov vyplýva, že táto metóda je časovo nenáročná.

Záver

V diplomovej práci sa zisťovali a overovali možnosti vyhľadávania podobných obrazov pomocou vhodných mier podobností v databáze textúr textílií a textilných vzorov. Testovacia obrazová sada obsahovala 20 naskenovaných obrazov tkanín a databázu textúr textílií a textilných vzorov. Naskenované tkaniny boli v základných typoch väzieb – plátno, keper, atlas, nasnímané v úrovniach šedi. Obrazová databáza textúr textílií a textilných vzorov, ktorá pochádza z Univerzitného E-Learningového Systému, obsahovala 364 obrazov plošných textílií prevažne tkanín a netkaných textílií.

Normalizovaná vzájomná korelácia je najčastejšie používanou technikou pri porovnávaní vzoru. Tradičná normalizovaná vzájomná korelácia ale nie je dostatočne citlivá na zmeny dvoch porovnávaných obrázkov. Nemôže efektívne rozlišovať rozdiely medzi bezchybnou a chybnou plochou v skúmanom obrázku. Je citlivá voči zmene osvetlenia a posunutia. V dôsledku tohto nedostatku bola použitá metóda založená na vlastných hodnotách kovariančnej matice mapy podobnosti medzi dvoma šedoúrovňovými obrázkami. Výsledky ukázali, že pri detekcii malých odchýlok v komplikovaných šedoúrovňových obrázkoch miera podobnosti pomocou vlastných čísiel je lepšia a efektívnejšia ako predchádzajúca metóda. Ďalšou testovanou metódou pre vyhľadávanie obrazov v databáze bola metóda latentného sémantického indexovania. Princípom metódy je redukcia dimenzionality a výpočet kosínusovej miery ako miery podobnosti medzi obrazom dotazovanej tkaniny a obrazmi textílií z databázy textúr. Pri testovaní metódy *LSI* výsledky ukázali, že metóda je citlivá pri natáčaní obrazu alebo vzoru v obraze. Ukázalo sa, ako vhodné použiť výkonové spektrá z *2D* Fourierovej transformácie, kde sa porovnáva obraz výkonového spektra hľadanej tkaniny s obrazmi výkonových spektier textílií z databázy textúr. Ďalšia použitá metóda bola založená na invariantných momentoch. Prístup je založený na porovnávaní hľadanej tkaniny s textíliami z databázy textúr pomocou siedmych invariantných momentov. Súbor týchto momentov je invariantný voči posunu, zmene veľkosti, zrkadlovému otočeniu a rotácií. Metóda používa ako mieru podobnosti Euklidovu vzdialenosť. Metóda porovnávania koreláciou bola použitá pre vyhľadávanie podobrázka (filter, maska) v databáze obrazov. Podobrázok je väčšinou menšieho rozmeru ako obraz databázy a obsahuje prevažne informácie o opakujúcom sa prvku. Jedným z prístupov nájdenia podobnosti je pracovať s vyhľadávaným podobrázkom

ako s priestorovým filtrom. Výsledkom je potom korelačná matica, kde vysoké hodnoty predstavujú miesta najlepšej zhody. Filtrácia v priestorovej oblasti je ale hardwarovo a časovo náročná. Alternatívnym prístupom je implementovať koreláciu vo frekvenčnej oblasti s využitím konvolučnej vety. Výhodou tejto metódy je nájdenie všetkých miest opakujúceho sa prvku. V prípade, že podobrázok (filter, maska) je práve strieda väzby, korelačná matica zobrazuje miesta rozloženia striedy v celej ploche obrazu.

Výsledky ukázali, že najlepšia je metóda latentného sémantického indexovania a to pomocou 2D Fourierovej transformácie, kde sa porovnávajú obrazy výkonových spektier. Metóda je rýchla a efektívna pri vyhľadávaní podobných obrazov v databáze textúr textílií a textilných vzorov.

Literatúra

- [1] TSAI, D.M., YANG, R.H. An Eigenvalue - based Similarity Measure and its Application in Defect Detection. *Image a Vision Computing*, Elsevier, 23 (12), pp. 1094-1101, 2005.
- [2] PRAKS, P. O vztahu mezi směrodatnou odchylkou a singulárními čísly SVD rozkladu. Ostrava. Katedra aplikované matematiky VŠB – TU Ostrava, 2005.
- [3] SKOPAL, T., SNÁŠEL, V. An Application of LSI and M-tree in Image Retrieval. *Technical report*. Ostrava, 2006.
- [4] HLAVÁČ, V., ŠONKA, M. *Počítačové vidění*. Praha: Grada, 1992. 272 s. ISBN 80-85424-67-3.
- [5] GONZALEZ, R.C., WOODS, R.E. *Digital Image Processing*. Prentice Hall, New Jersey: Upper Saddle River, 2002. 609 s. ISBN 0-201-18075-8.
- [6] Dictionary. com – Find the Meanings and Definitions of Words at Dictionary. com. [cit. 2010-04-12]. Dostupné z: <http://dictionary.reference.com>.
- [7] KRÁTKÝ, M. Využití SVD pro indexování latentní sémantiky. Ostrava: VŠB Technická univerzita Ostrava, 2002.
- [8] PRAKS, P., DVORSKÝ, J., SNÁŠEL, V. Latent Semantic Indexing for Image Retrieval Systems. Siam Conference in Applied Linear Algebra (LA03), the College of William and Mary. Williamsburg, USA, 2003.
- [9] Univerzitní e-learningový systém – E-learning. [cit. 2010-03-11]. Dostupné z: http://blade1.ft.tul.cz/~tyr/cgi-bin/elearning/elearning.fcgi?page=publ&action=showThemeContent&theme_id=22
- [10] CHAN, C.H., PANG, K.H. Fabric Defect Detection by Fourier Analysis. *IEEE Transaction on Industry Applications*, 23 (12), pp. 1094-1101, 2005.
- [11] TSAI, D.M., LIN, C.T. Fast normalized cross correlation for defect detection. *Pattern Recognition Letters*, Elsevier, 24 (15), pp. 2625-2631, 2003.

-
- [12] PRAUS, P., PRAKS, P. Automatic retrieval within water-related pictures database using latent semantic indexing method. *GeoScience Engineering*, 2 (2009) 19-28. VŠB – Technical University of Ostrava. ISSN 1802-5420.
- [13] HOUDEK, P., SCHWARZ, J., SNÁŠEL, V. Moderní metody vyhledávání dokumentů v rozsáhlých plnotextových databázích: příklad vektorového modelu. *Ikaros*. 2003. ISSN 1212-5057.
- [14] LANDAUER, T.K., FOLTZ, P.W., LAHAM, D. An Introduction to Latent Semantic Analysis. *Discourse Processes*, 25 (2&3), pp. 259-284, 1998.

Prílohy

Príloha č. 1 Zdrojové kódy pre MATLAB

Príloha č. 2 Testovacia sada 1

Príloha č. 3 Testovacia sada 2

Príloha č. 4 Testovacia sada 3

Príloha č. 5 Testovacia sada 4

Príloha č. 1 Zdrojové kódy pre MATLAB

Zdrojový kód – ncc.m

```
clear *;
clc
% NCC - Normalizovana vzajemna korelacia

% VOLBY NASTAVENIA
% velkost okienka
xvelOkno = 20;
yvelOkno = 20;

% prah pre vyhodnotenie chyby
prah = 0.8;

% XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX

% nacitanie obrazkov
V = imread('tka.jpg'); %vzor
T = imread('tkb.jpg'); %kontrolovaný

% zobrazenie originalu
subplot(3,2,1)
imshow(V)
subplot(3,2,2)
imshow(T)

% prevod na sedourovnovy
Vsedy = rgb2gray(V);
Tsedy = rgb2gray(T);

% zobrazenie sedych obr
subplot(3,2,3)
imshow(Vsedy)
subplot(3,2,4)
imshow(Tsedy)

% rozmery obrazku
[yvelObr, xvelObr] = size(Vsedy)

% NCC pre posuve okienko
NCC = zeros(yvelObr-yvelOkno, xvelObr-xvelOkno); % vytvorenie prazdnej matice NCC
NCCobr = zeros(yvelObr-yvelOkno, xvelObr-xvelOkno); % vytvorenie prazdnej matice NCC ako obrazku
A = zeros(yvelOkno, xvelOkno); % vytvorenie prazdenej matice okienka u vzoru
B = zeros(yvelOkno, xvelOkno); % vytvorenie prazdenej matice okienka u kontrolovaneho
for y = 1 : (yvelObr-yvelOkno+1)
    for x = 1 : (xvelObr-xvelOkno+1)

        % vypocet NCC
        A = Vsedy(y : y+yvelOkno-1, x : x+xvelOkno-1);
        B = Tsedy(y : y+yvelOkno-1, x : x+xvelOkno-1);
        NCC(y, x) = corr2(A,B);
```

```

        if (NCC(y, x) < prah)
            NCCobr(y, x) = 0; % cierna plocha(chyba)
        else
            NCCobr(y, x) = 255; % biela polcha
        end
    end
end

% NCC pre cely obrazok
NCCcelok = corr2(Vsedy, Tsedy);

% zobrazenie vysledku NCC
subplot(3,2,5)
imshow(NCCobr)

```

Zdrojový kód – vlc.m

```

clear *;
clc
% vlastne cisla

% XXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXXX

% nacitanie obrazkov
V = imread('tka.jpg'); %vzor
T = imread('tkb.jpg'); %kontrolovany

% zobrazenie originalu
subplot(3,2,1)
imshow(V)
subplot(3,2,2)
imshow(T)

% prevod na sedourovnovy
Vsedy = rgb2gray(V);
Tsedy = rgb2gray(T);

% zobrazenie sedych obr
subplot(3,2,3)
imshow(Vsedy)
subplot(3,2,4)
imshow(Tsedy)

% rozmary obrazku
[yvel0br, xvel0br] = size(Vsedy)

korrmap = zeros(256,256); % vytvorenie prazdnej matice korespondencnej
mapy
M = zeros(2,2); % vytvorenie prazdnej kovariancnej matice
VLC = zeros(1,2); % vytvorenie prazdnej matice VLC

% vypocet korespondencnej mapy pre cely obrazok
for y = 1 : yvel0br
    for x = 1 : xvel0br
        % korespondencna mapa
    end
end

```

```

        korrmap(256-Tsedy(y,x), Vsedy(y,x)+1) = korrmap(256-
Tsedy(y,x),Vsedy(y,x)+1)+1;
    end
end

% vypocet pre cely obrazok
% vypocet kovariancnej matice
M = cov(double(Vsedy),double(Tsedy),1);

% vypocet vlasnych cisiel
VLC = eig(M);

% vypocet korelacneho koeficientu
m11 = M(1,1);
m22 = M(2,2);
m12 = M(1,2);
R = m12/sqrt(m11*m22);

% vypocet pre okienko
% Mo = zeros(2,2); % vytvorenie prazdnej kovariancnej matice
% VLCo = zeros(yvelObr-yvelOkno,xvelObr-xvelOkno); % vytvorenie prazdnej
matice VLC
%
% for y = 1 : (yvelObr-yvelOkno+1)
%     for x = 1 : (xvelObr-xvelOkno+1)
%
%         vypocet kovariancnej matice pre okienko
%         A = Vsedy(y : y+yvelOkno-1, x : x+xvelOkno-1);
%         B = Tsedy(y : y+yvelOkno-1, x : x+xvelOkno-1);
%         Mo = cov(double(A),double(B),1);
%
%         vypocet vlasnych cisiel pre okienko
%         pomVLCo = eig(Mo);
%         VLCo(y,x) = pomVLCo(1,1);
%
%         vypocet korelacneho koeficientu pre okienko
%         m11o = Mo(1,1);
%         m22o = Mo(2,2);
%         m12o = Mo(1,2);
%         Ro = m12o/sqrt(m11o*m22o);
%
%
%         if (VLCo(y,x) < prah)
%             VLCobr(y, x) = 255; % čierna plocha(chyba)
%         else
%             VLCobr(y, x) = 0; % biela plocha
%         end
%     end
% end
% end

% zobrazenie korespondenčnej mapy
subplot(3,2,5)
imshow(korrmap)
korrmap_i = abs(korrmap-255);
subplot(3,2,6)
imshow(korrmap_i,[])

```

```
% % zobrazenie vysledku VLC
% subplot(3,2,6)
% imshow(VLCobr)
```

Zdrojový kód – lsi_01.m

```
clear,clc,close all

m=250;
n=250;
po=20;
name='.bmp';
for t=1:po
    I=imread([num2str(t) name]);
    I=imcrop(I,[100 100 m-1 m-1]);
    I=double(I);
    %I=histeq(I);
    % figure(t),imshow(I,[])
    a=reshape(I,(m*n),1);
    A(:,t)=a;
end
[mm nn]=size(A);
k=20;
[U,S,V] = svds(A,k);

query=imread('14.bmp');
query=imcrop(query,[100 100 m-1 m-1]);
query=double(query);
%query=histeq(query);
figure,imshow(query,[])
query=reshape(query,(m*n),1);

qc=query'*U*inv(S);

for j=1:nn
    sim(j)=(qc*V(j,:))/(norm(qc)*norm(V(j,:)));
end
[C,Ind] = max(sim);
miera_podobnosti=C

figure
plot (1:po,sim(1,1:nn),'-*', 'DisplayName', 'sim(1,1:nn)', 'YDataSource',
'sim(1,1:nn)')
ylabel('Sim'),xlabel('Ti')
text1=['    miera podobnosti = ' num2str(C) ' ; index = ' num2str(Ind)];
text(Ind,C,text1,'HorizontalAlignment','left')

% Restored image
A1=U*S*V';
A2=reshape(A1(:,Ind),m,n);
A3=uint8(A2);
figure,imshow(A2,[])
```

Zdrojový kód – rotacia.m

```
clear,clc,close all
tic
%% nacitanie obrazku

I=imread('R 017 rot 4.bmp');
I=I(501:700,501:700);
[rr ss]=size(I);
poka=I;
for J=1:rr
    for K=1:ss
        pom=(J-(floor(rr+1)/2))^2+(K-(floor(ss+1)/2))^2;
        if pom>(rr/2)^2
            poka(J,K)=0;
        end;
    end;
end;

query=poka;
query=double(query);
query=reshape(query,(rr*ss),1);

uhel=90;
vek=-uhel:1:uhel;
pp=0;
for i=vek
    pp=pp+1;
    Ii=imrotate(poka,i,'bicubic','crop');
    figure,imshow(Ii,[])
    Ii=double(Ii);
    [m n]=size(Ii);
    a=reshape(Ii,(m*n),1);
    A(:,pp)=a;
end
[mm nn]=size(A);
k=20;
[U,S,V] = svds(A,k);

qc=query'*U*inv(S);

for j=1:nn
    sim(j)=(qc*V(j,:))'/(norm(qc)*norm(V(j,:)));
end
[C,I] = max(sim);
miera_podobnosti=C

figure
plot (vek,sim(1,1:nn),'-*', 'DisplayName', 'sim(1,1:nn)', 'YDataSource',
'sim(1,1:nn)')
ylabel('Sim'),xlabel('U[°]')
%text1=[' miera podobnosti = ' num2str(C) '; index = ' num2str(I)];
%text(I,C,text1,'HorizontalAlignment','left')
```

Zdrojový kód – lsi_rot.m

```
clear,clc,close all
tic
```

```

m=200;
n=200;
po=20;
name='.bmp';
for t=1:po
    I=imread([num2str(t) name]);
    I=imcrop(I,[100 100 m-1 m-1]);
    I=double(I);
    %I=histeq(I);
    %figure(t),imshow(I,[])
    a=reshape(I,(m*n),1);
    A(:,t)=a;
end
[mm nn]=size(A);
k=20;
[U,S,V] = svds(A,k);

query=imread('R 017 rot 4.bmp');
query=imcrop(query,[500 500 500 500]);
figure,imshow(query,[])
uhel=-25:25;
SIMIL=zeros(length(uhel),po);
cit=0;
for u=uhel;
    cit=cit+1;
    queryR=imrotate(query,u,'crop');
    queryR=imcrop(queryR,[200 200 m-1 m-1]);
    queryR=double(queryR);
    %figure,imshow(queryR,[])
    queryR=reshape(queryR,(m*n),1);
    qc=queryR'*U*inv(S);
    for tt=1:po
        SIMIL(cit,tt)=(qc*V(tt,:))'/(norm(qc)*norm(V(tt,:)));
    end
end
[r c]=find(SIMIL==max(max(SIMIL)));
[uhel(r) c]
figure,plot(SIMIL(r,:),'-b.',ylabel('Sim'),xlabel('Ti'),hold on
plot(c,SIMIL(r,c),'ro')
axis([1 po -1 1.2])
text1=['miera podobnosti = ' num2str(max(max(SIMIL))) ' ; index = '
num2str(c)];
text(3.3,max(max(SIMIL)),text1,'HorizontalAlignment','left')
Ivysl=imread([num2str(c) name]);
figure,imshow(Ivysl,[])

toc

```

Zdrojový kód – lsi_FT.m

```

clear,clc,close all
tic
m=100;
n=100;
po=20;
name='.bmp';
for t=1:po
    I=imread([num2str(t) name]);
    if size(I,3)>1

```

```

        I=rgb2gray(I);
    end
    I=imcrop(I,[100 100 m-1 m-1]);
    I=double(I);
    FT=fftshift(fft2(I));
    P=log(1+abs(FT));
    %I=histeq(I);
    % figure(t),imshow(I,[])
    a=reshape(P,(m*n),1);
    A(:,t)=a;
end
[mm nn]=size(A);
k=20;
[U,S,V] = svds(A,k);

query=imread('4.bmp');
if size(query,3)>1
    query=rgb2gray(query);
end
query=imcrop(query,[500 500 500 500]);
figure,imshow(query,[])
uhel=-25:25;
SIMIL=zeros(length(uhel),po);
cit=0;
for u=uhel;
    cit=cit+1;
    queryR=imrotate(query,u,'crop');
    queryR=imcrop(queryR,[200 200 m-1 m-1]);
    queryR=double(queryR);
    % figure,imshow(queryR,[])
    FTq=fftshift(fft2(queryR));
    Pq=log(1+abs(FTq));
    % figure,imshow(Pq,[])
    queryR=reshape(Pq,(m*n),1);
    qc=queryR'*U*inv(S);
    for tt=1:po
        SIMIL(cit,tt)=(qc*V(tt,:))'/(norm(qc)*norm(V(tt,:)));
    end
end
[r c]=find(SIMIL==max(max(SIMIL)));
[uhel(r) c];
figure,plot(SIMIL(r,:),'-b.'),ylabel('Sim'),xlabel('Ti'),hold on
plot(c,SIMIL(r,c),'ro')
axis([1 po -1 1.2])
text1=['miera podobnosti = ' num2str(max(max(SIMIL))) ' ; index = '
num2str(c)];
text(7.3,max(max(SIMIL)),text1,'HorizontalAlignment','left')
Ivysl=imread([num2str(c) name]);
figure,imshow(Ivysl,[])

toc

```

Zdrojový kód – inv_obrazky.m

```

clear,clc,close all
f=imread('a1.bmp');
figure, imshow(f)
fs=rgb2gray(f);
figure, imshow(fs)

```

```

fp=padarray(fs,[84 84],'both'); % originalny
figure, imshow(fp)
fhs=fs(1:2:end,1:2:end);
fhsp=padarray(fhs,[184 184],'both'); % polovicna velkost
figure, imshow(fhsp)
fm=fliplr(fs);
fmp=padarray(fm,[84 84],'both'); % zrkadlovo otoceny
figure, imshow(fmp)
fr2=imrotate(fs,2,'bilinear');
fr2p=padarray(fr2,[76 76],'both'); % otoceny o 2 stupne
figure, imshow(fr2p)
fr45=imrotate(fs,45,'bilinear');
fr45p=padarray(fr45,[76 76],'both'); % otoceny o 45 stupnov
figure, imshow(fr45p)

phiorig=abs(log(invmoments(fs)))
phipol=abs(log(invmoments(fhs)))
phizrkad=abs(log(invmoments(fm)))
phirot2=abs(log(invmoments(fr2)))
phirot45=abs(log(invmoments(fr45)))

```

Zdrojový kód – inv_01.m

```

clear,clc,close all
tic
po=364;
name='.bmp';
vysl=zeros(po,8);
for t=1:po
    I=imread([num2str(t) name]);
    if size(I,3)>1
        I=rgb2gray(I);
    end
    phi=abs(log(invmoments(I)));
    vysl(t,1:7)=phi;
end

dotaz=imread('5.bmp');
phidotaz=abs(log(invmoments(rgb2gray(dotaz))));

for i=1:po
    vysl(i,8)=pdist([phidotaz; vysl(i,1:7)],'euclidean');
end
figure,plot(vysl(:,end))
ylabel('dE'),xlabel('Ti'),hold on

toc

```

Zdrojový kód – cormatch.m

```

clear,clc,close all

oknor=35;
oknos=145;
odr=283;
ods=328;

I=imread('100.bmp');

```

```

I=rgb2gray(I);
I1=I(1:500,1:500);
figure,imshow(I1,[])
rectangle('Position',[ods,odr,oknos-1,oknor-1], 'EdgeColor','r', 'LineWidth',1)
dotaz=imcrop(I1,[ods odr oknos-1 oknor-1]);
figure,imshow(dotaz,[])

g=dftcorr(I1,dotaz);
gs=gscale(g);
figure,imshow(gs)

[I, J]=find(g==max(g(:)));
figure,imshow(gs>254)

%Ivysl=I1(I:I)

```

Zdrojový kód – dftcorr.m

```

function g=dftcorr(f,w)

[M, N]=size(f);
f=fft2(double(f));
w=conj(fft2(w,M,N));
g=real(ifft2(w.*f));

```

Zdrojový kód – cormatch_01.m

```

clear,clc,close all

oknor=75;
oknos=75;
odr=52;
ods=39;

D=imread('5.bmp');
D=double(D);
D=D(101:400,101:400);
dotaz=imcrop(D,[ods odr oknos-1 oknor-1]);
figure,imshow(dotaz,[])

name='.bmp';
pole=[];
for iii=1:364
I=imread([num2str(iii) name]);
I=double(I);
I1=I(101:400,101:400);
I2=zeros(size(I1,1)+oknor,size(I1,2)+oknos);
I2(1:size(I1,1),1:size(I1,2))=I1;
g=dftcorr(I1,dotaz);
gs=gscale(g);
M=max(g(:));
[ic, jc]=find(g==M);
r=corr2(dotaz,I2(ic:ic+oknor-1,jc:jc+oknos-1));
pole=[pole; iii r ic jc];
end
pole

```


```

[rc sc]=find(pole(:,2)==max(pole(:,2)));
figure
Ic=imread([num2str(pole(rc,1)) name]);
Ic=Ic(101:400,101:400);
subplot(2,2,1),imshow(D,[],),
rectangle('Position',[ods,odr,oknos,oknor],'EdgeColor','r','LineWidth',2)
subplot(2,2,2),imshow(Ic,[],),
rectangle('Position',[pole(rc,4),pole(rc,3),oknos,oknor],'EdgeColor','y')
gc=dftcorr(Ic,dotaz);
gsc=gscale(gc);
subplot(2,2,3),imshow(gsc,[],)
subplot(2,2,4),imshow(im2bw(gsc,0.8))


figure,plot(pole(:,2),'.-'),hold on
plot(pole(rc,1),pole(rc,2),'or')
ylabel('Sim'),xlabel('Ti')
text1=[' 2D corrcoeff =' num2str(pole(rc,2)) '; index = '
num2str(pole(rc,1))];
text(3.1,pole(rc,2),text1,'HorizontalAlignment','left')

```


Príloha 2. Testovacia sada 1




(S4)




$k = 20$




(d)




(S9)




$k = 20$




(e)




(S10)




$k = 20$




(f)



(S13)





$k = 20$





(g)

Obr. 15 (S) dotazovaná tkanina, (d) – (g) vyhl'adaná tkanina, grafy *sim*.



Príloha 3. Testovacia sada 2





(S2)





(S3)





(S4)





(S5)





(S6)





(S7)





(S8)





(S9)





(S10)





(S11)





(S12)





(S13)





(S15)





(S16)





(S17)



(S18)




(S19)




(S20)

Obr. 19 (S2) - (S20) Dotazovaná tkanina, grafy *sim*.


Príloha 4. Testovacia sada 3




(D294)




$k = 10$




(a4)




$k = 13$




(a5)




$k = 20$



(a6)




$k = 150$




(a7)


Obr. 21 (D294) Dotazovaná netkaná textília, (a4) – (a7) vyhl'adaná textília, grafy *sim*.




(D5)




$k = 7$




(a2)




$k = 10$




(a3)




$k = 13$




(a4)




$k = 50$





(a5)



$k = 150$




(v6)




(a7)

$$k = 250$$


Obr. 22 (D5) Dotazovaná tkanina, (a2) – (a7) vyhládaná textília, grafy *sim*.




(D38)




$$k = 7$$




(a2)




$$k = 10$$




(a3)




$k = 13$




(a4)




$k = 50$





(a5)



$k = 150$




(a6)





(a7)

$$k = 250$$

Obr. 23 (D38) Dotazovaná tkanina, (a2) – (a7) vyhl'adaná textília, grafy sim .





(D318)





(a2)

$$k = 7$$





(a3)

$$k = 10$$





(a4)

$k = 13$





(a5)

$k = 50$



(a6)

$k = 150$




(b7)


$$k = 250$$

Obr. 24 (D318) Dotazovaná netkaná textília, (a2) – (a7) vyhl'adaná textília, grafy *sim*.


Príloha 5. Testovacia sada 4




(R15-r1)




$k = 2$




(a2)




$k = 3$




(a3)




$k = 4$




(a4)




$k = 10$




(a5)




$k = 13$




(a6)




$k = 15$




(a7)




$k = 17$




(a8)




$k = 19$




(a9)




$k = 20$




(a10)




$k = 50$



(a11)




$k = 250$




(a12)


Obr. 26 (R15-r1) Dotazovaná tkanina, (a2) – (a12) vyhľadaná tkanina, grafy *sim*.




(R15-r2)




$k = 15$





(a2)



$k = 20$




(a3)




(a4)

$$k = 50$$


Obr. 27 (R15-r2) Dotazovaná tkanina, (a2) – (a4) vyhládaná tkanina, grafy *sim*.




(R15-r3)




$k = 10$




(a2)




$k = 17$




(a3)




$k = 20$



(a4)




$k = 50$




(a5)


Obr. 28 (R15-r3) Dotazovaná tkanina, (a2) – (a5) vyhládaná tkanina, grafy *sim*.




(R15-r4)




$k = 15$




(a2)




$k = 17$




(a3)




$k = 20$



(a4)




$k = 50$





(a5)

Obr. 29 (R15-r4) Dotazovaná tkanina, (a2) – (a5) vyhládaná tkanina, grafy *sim*.





(R17-r1)




(a2)

$k = 6$




(a3)


$k = 12$




$k = 14$




(a4)




$k = 18$





(a5)



$k = 20$




(a6)




(a7)

$$k = 50$$


Obr. 30 (R17-r1) Dotazovaná tkanina, (a2) – (a7) vyhládaná tkanina, grafy *sim*.




(R17-r2)




$k = 6$




(a2)




$k = 8$




(a3)




$k = 15$




(a4)




$k = 18$





(a5)



$k = 20$




(a6)





(a7)

$k = 50$

Obr. 31 (R17-r2) Dotazovaná tkanina, (a2) – (a7) vyhládaná tkanina, grafy *sim*.





(R17-r3)




(a2)

$k = 5$




(a3)


$k = 7$




$k = 15$




(a4)




$k = 18$





(a5)



$k = 20$




(a6)




(a7)

$k = 50$


Obr. 32 (R17-r3) Dotazovaná tkanina, (a2) – (a7) vyhládaná tkanina, grafy *sim*.




(R17-r4)




$k = 6$




(a2)




$k = 15$




(a3)




$k = 18$




(a4)




$k = 20$



(a5)




$k = 50$




(a6)


Obr. 33 (R17-r4) Dotazovaná tkanina, (a2) – (a6) vyhl'adaná tkanina, grafy *sim*.




(S10)




$k = 6$




(a3)




$k = 11$




(a4)




$k = 15$




(a5)




$k = 20$



(a6)




$k = 50$




(a7)


Obr. 34 (S10) Dotazovaná tkanina, (a3) – (a7) vyhl'adaná tkanina, grafy *sim*.




(S15)




$k = 17$





(a3)



$k = 19$





(a4)



(a5)


$k = 20$




(a6)

$k = 50$


Obr. 35 (S15) Dotazovaná tkanina, (a3) – (a6) vyhledaná tkanina, grafy *sim*.




(S7)




$k = 4$




(a2)




$k = 8$




(a3)




$k = 15$




(a4)




$k = 20$



(a5)




$k = 50$




(a6)


Obr. 36 (S7) Dotazovaná tkanina, (a2) – (a6) vyhl'adaná tkanina, grafy *sim*.




(D5)



$k = 3$




(a2)




$k = 4$




(a3)




$$k = 8$$




(a4)




$$k = 16$$





(a5)



$$k = 20$$




(a6)





(a7)

$$k = 50$$

Obr. 37 (D5) Dotazovaná tkanina, (a2) – (a7) vyhládaná textília, grafy *sim*.





(D38)




(a2)

$k = 3$




(a3)


$k = 4$




$k = 5$




(a4)




$k = 16$





(a5)



$k = 20$




(a6)




(a7)

$$k = 50$$


Obr. 38 (D38) Dotazovaná tkanina, (a2) – (a7) vyhládaná textília, grafy *sim*.




(D294)




$k = 3$




(a2)




$k = 4$




(a3)




$k = 5$




(a4)




$k = 8$





(a5)



$k = 20$




(a6)




(a7)

$$k = 50$$


Obr. 39 (D294) Dotazovaná netkaná textília, (a2) – (a7) vyhládaná textília, grafy *sim*.




(D318)




$k = 3$




(a2)




$k = 5$




(a3)




$k = 8$




(a4)




$k = 16$





(a5)



$k = 20$



(a6)



(a7)

$$k = 50$$

Obr. 40 (D318) Dotazovaná netkaná textília, (a2) – (a7) vyhládaná textília, grafy *sim*.